

UNIVERSITÉ DU QUÉBEC À TROIS-RIVIÈRES

REVUE SYSTÉMATIQUE DES APPROCHES
ALGORITHMIQUES DE FUZZY C-MEANS
APPLIQUÉES À LA SEGMENTATION D'IMAGES
MÉDICALES

MÉMOIRE PRÉSENTÉ
COMME EXIGENCE PARTIELLE DE LA

MAÎTRISE EN MATHÉMATIQUES ET INFORMATIQUE
APPLIQUÉES

PAR
CHÉRIFA IMELDA TOKO

FÉVRIER 2025

Université du Québec à Trois-Rivières

Service de la bibliothèque

Avertissement

L'auteur de ce mémoire, de cette thèse ou de cet essai a autorisé l'Université du Québec à Trois-Rivières à diffuser, à des fins non lucratives, une copie de son mémoire, de sa thèse ou de son essai.

Cette diffusion n'entraîne pas une renonciation de la part de l'auteur à ses droits de propriété intellectuelle, incluant le droit d'auteur, sur ce mémoire, cette thèse ou cet essai. Notamment, la reproduction ou la publication de la totalité ou d'une partie importante de ce mémoire, de cette thèse et de son essai requiert son autorisation.

REMERCEMENTS

Je souhaite tout d'abord remercier mes professeurs de suivi qui m'ont donné l'occasion de travailler sur ce sujet qui est autant novateur qu'important pour moi.

Merci également à tout le corps professoral pour ses enseignements et sa disponibilité qui m'ont permis de franchir chaque étape de mes études dans les meilleures conditions. L'amour de leur travail a été pour moi une réelle source d'inspiration.

Je souhaite aussi remercier tous mes proches et amis, et tout spécialement ma mère, mon mari et mon fils qui m'ont permis d'être là où je suis actuellement. Merci infiniment pour votre écoute, votre patience et votre soutien inconditionnel. Sans vous, rien de tout cela n'aurait été possible.

Enfin, je tiens à remercier l'université du Québec à Trois-Rivières de me permettre de présenter le résultat de mes recherches sur ce sujet très intéressant et important qu'est la segmentation de l'imagerie médicale.

Résumé

Les algorithmes de clustering sont de plus en plus utilisés dans de nombreux domaines. Le but de ces algorithmes est de donner un sens aux données et d'en extraire de la valeur à partir de grandes quantités de données structurées et non structurées afin de les regrouper dans différents clusters ou groupes en fonction de leurs similitudes. Dans les domaines comme celui de l'imagerie médicale, la segmentation d'image est une tâche cruciale qui permet d'isoler dans l'image les objets significatifs sur lesquels doit porter l'analyse afin de réaliser le diagnostic, la planification et le suivi des traitements et opérations. En raison de sa simplicité et de son efficacité, Fuzzy c-means (FCM) est l'approche de regroupement la plus couramment employée pour la segmentation d'images. Cependant, la segmentation d'image médicale fait encore face à de nombreux défis en raison de la complexité de ce type d'image due souvent au manque de clarté des clichés, aux limites floues des zones observées, à leur structure complexe, et à des facteurs externes comme la présence de bruit. Cette complexité induit une diminution de l'efficacité de la méthode FCM entraînant le blocage dans les optimums locaux, la sensibilité au bruit pouvant conduire à une mauvaise segmentation et à une mauvaise interprétation des résultats.

Face à ces obstacles, nous avons répertorié plusieurs optimisations à différents niveaux de cette méthode de clustering, à savoir les optimisations au niveau du prétraitement de l'image, celles au niveau du choix des paramètres initiaux et enfin les optimisations au niveau du calcul des centroïdes. Notre revue systématique fait état de ces optimisations et de leurs différents apports pour la méthode FCM.

Mots clés : Clustering flou, Fuzzy c-means (FCM), Segmentation, image médicale, optimisations, réduction du bruit, égalisation d'histogramme, analyse de performance, Machine Learning / Deep Learning (ML / DL)

Abstract

Clustering algorithms are increasingly used in many fields. The aim of these algorithms is to make sense of data and extract value from large quantities of structured and unstructured data, in order to group them into different clusters or groups based on their similarities. In fields such as medical imaging, image segmentation is a crucial task, enabling us to isolate significant objects in the image for analysis in order to diagnose, plan and monitor treatments and operations. Due to its simplicity and efficiency, Fuzzy c-means (FCM) is the most commonly used clustering approach for image segmentation. However, medical image segmentation still faces many challenges due to the complexity of this type of image, often caused by the lack of clarity of the images, the blurred boundaries of the areas observed, their complex structures, and external factors such as the presence of noise. This complexity leads to a reduction in the efficiency of the FCM method, resulting in blocking in local optimums, while noise sensitivity can lead to poor segmentation and bad interpretations of the results.

Faced with these obstacles, we have listed several optimizations at different levels of the fuzzy clustering method, namely optimizations at the level of image pre-processing, those at the level of the choice of initial parameters, and finally optimizations at the level of centroid calculation. Our systematic review reports on these optimizations and their different contributions to the FCM method.

Keywords : Fuzzy clustering, Fuzzy c-means, Segmentation, medical image, optimizations, noise reduction, histogram equalization, performance analysis, Machine Learning/Deep Learning (ML/DL).

Table des matières

1	Introduction	10
2	Concepts de bases et définitions	13
2.1	Introduction	13
2.2	Concepts clés du clustering	13
2.3	Types de clustering	14
2.3.1	Domaines d'applications	15
2.4	La logique floue	17
2.4.1	Définition	17
2.4.2	Concepts	18
2.5	Le clustering flou	19
2.5.1	Avantages et inconvénients de l'algorithme FCM	24
2.5.2	Applications de FCM dans la segmentation d'images médicales	25
2.6	Quelques optimisations	26
2.7	Conclusion	27
3	État de l'art	29
3.1	Introduction	29
3.2	L'intelligence artificielle (IA) dans le domaine médical .	30
3.3	L'IA et la segmentation d'image médicale	31
3.4	Les architectures hybrides	33
3.5	Les techniques de segmentation d'image médicale . . .	34
3.6	Le clustering et la segmentation médicale	35
3.7	Les défis de l'imagerie médicale	37
3.8	Conclusion	38
4	Méthodologie de recherche	39
4.1	Introduction	39

4.2	Questions de recherche	39
4.3	Les mots-clés	42
4.4	Les bases de données	42
4.5	Résultats	43
4.6	Conclusion	43
5	FCM et ses optimisations	44
5.1	Introduction	44
5.2	Optimisations au niveau du prétraitement des images :	
	Débruitage	44
	5.2.1 Les filtres traditionnels	45
	5.2.2 L'égalisation des histogrammes	51
5.3	Optimisations du choix des paramètres initiaux	54
5.4	Optimisations de la mise à jour des centroïdes	72
	5.4.1 Mise à jour des centroïdes	74
	5.4.2 Modification de la fonction objective	78
5.5	Conclusion	100
6	Conclusion	103

Table des figures

2.1	Exemple visuel de clustering strict vs clustering flou . . .	16
2.2	Graphique d'illustration de la logique floue	18
2.3	Image d'IRM	25
2.4	Image de Scanner	26
2.5	Image d'échographie	26
2.6	Schéma récapitulatif de l'algorithme génétique	28
4.1	Étapes de notre méthodologie de recherche	41
5.1	Comparaison des méthodes de réduction de bruit pour FCM	51
5.2	Comparaison étendues des algorithmes d'optimisation des paramètres initiaux : Précision, robustesse et temps d'exécution	72
5.3	Comparaison étendues des algorithmes améliorant la mise à jour des centroïdes : Précision, robustesse et temps d'exécution	79
5.4	Comparaison étendues des algorithmes pour les optimi- sations au niveau de la fonction objective	102

Liste des tableaux

2.1	Clustering strict vs Clustering flou	16
4.1	Bases de données exploitées	43
5.1	Résumé des méthodes de réduction du bruit par utilisation des filtres	51
5.2	Résumé des méthodes de réduction du bruit avec l'égalisation des histogrammes	54
5.3	Résumé des méthodes d'optimisations au niveau du choix des paramètres initiaux(1)	70
5.4	Résumé des méthodes d'optimisations au niveau du choix des paramètres initiaux(2)	71
5.5	Résumé des méthodes utilisant la mise à jour des centroïdes	78
5.6	Résumé des méthodes utilisant la modification de la fonction objective (1)	99
5.7	Résumé des méthodes utilisant la modification de la fonction objective (2)	100
5.8	Résumé des méthodes utilisant la modification de la fonction objective (3)	101

List of Algorithms

1	Étapes de FCM	22
2	Étapes de FCM pour la segmentation	24
3	Algorithme CLAHE	53
4	Algorithme génétique	56
5	Pseudo-code Algorithme de lucioles	57
6	Algorithme BBO	58
7	Algorithme de SAJAYA	62
8	Algorithme IKCM	64
9	Algorithme d'optimisation Black Widow	66
10	Algorithme GWO	74
11	Algorithme FCM-WOA	76
12	Masquage dynamique 3D	83
13	Algorithme ImFCM	93

Chapitre 1

Introduction

Le clustering ou regroupement est une méthode d'apprentissage automatique qui consiste à regrouper des points de données par similarité ou par distance. C'est une méthode d'apprentissage non supervisée et une technique populaire d'analyse statistique des données. Pour un ensemble donné de points, il existe plusieurs algorithmes de classification pour classer des points de données individuels dans des groupes spécifiques.

Au début des années 1987, l'algorithme de clustering des moyennes floues FCM a été introduit par Dunn et perfectionné en 1981 par Bezdek J.C. pour pallier les algorithmes de clustering plus « durs » comme K-means qui ne prenaient pas en compte certaines similarités faibles mais non négligeables entre les points de données. Sur la base du concept de fonction objective, le FCM est la meilleure technique complète et c'est la raison pour laquelle il est largement utilisé.

Dans le domaine médical, l'introduction de FCM a permis plusieurs avancées dans la segmentation d'image pour la détection d'anomalies, la prévention de maladies, l'aide à la décision et bien d'autres améliorations. Cependant, certaines limitations à cet algorithme subsistent dans son utilisation au sein du domaine médical. En effet, la sensibilité aux bruits, l'enfermement dans les optimums locaux et le manque de fiabilité face aux zones non sphériques sont des obstacles à franchir pour une meilleure segmentation de ce type d'images.

L'objectif de notre étude est de réaliser une revue systématique détaillée sur les différentes approches algorithmiques de type Fuzzy c-means, les différentes variantes et évolutions de cet algorithme au cours des cinq dernières années. Nous cherchons également à obser-

ver comment ces optimisations ont impacté positivement ou négativement cette méthode en termes de robustesse, d'efficacité de calcul, de précision de regroupement et de classification. Les buts de cette manœuvre étant la mise en place d'un répertoire des différentes méthodes d'optimisation ayant impacté pour le mieux l'algorithme dans la segmentation d'image médicale avec les enjeux de chacune de ces méthodes, à savoir l'emplacement de l'optimisation, ses avantages et inconvénients, l'environnement de développement, et les documentations trouvées dans le cadre de notre étude. Et également de dégager des pistes non encore explorées.

À cet effet, au cours de notre étude, nous avons exploré quatre bases de données à savoir : IEEExplore, SpringerLink, EBSCO et Scopus qui sont mises à disposition dans les ressources bibliothécaires de notre université (UQTR). Grâce à une recherche à l'aide de mots-clés spécifiques choisis pour répondre à l'objectif de notre étude (Fuzzy C-means, Optimisation, segmentation, image médicale), nous avons pu obtenir **2338** articles initiaux. Ensuite, nous avons sélectionné un par un les articles les plus pertinents pour notre étude grâce à une lecture préliminaire et à l'élimination des doublons. À la suite de ces procédés, nous avons pu retenir **82** articles que nous utiliserons tout au long de notre étude afin de répondre à nos questions de recherche qui sont de savoir quelles sont les optimisations et à quel niveau de l'algorithme FCM sont-elles implémentées ainsi que les avantages et les inconvénients de ces optimisations en termes de robustesse, d'efficacité de calcul et de précision lors du regroupement.

Ces articles divers et variés nous ont permis de définir plusieurs niveaux d'optimisation qui permettent d'améliorer l'algorithme Fuzzy c-means. Parmi ces optimisations, nous avons : le prétraitement des images à segmenter (processus de débruitage, d'augmentation des pixels, d'éclaircissement des zones d'intérêts, retrait des zones de faibles intérêts), les optimisations au niveau de l'initialisation (pour le choix des paramètres initiaux comme le nombre de grappes, le nombre d'itérations, le paramètre de flou,...) et les optimisations au niveau de la mise à jour des centroïdes (détermination de zones plus pertinentes grâce à de nouveaux algorithmes de calcul, mise en place de nouvelles fonctions objectives).

La structure restante de notre étude est la suivante : dans la section 2, nous abordons l'état de l'art avec divers travaux, dans la section 3, nous présentons une vue d'ensemble sur les concepts et définitions de base en lien avec notre étude. Puis, dans la section 4, nous présentons la méthodologie utilisée pour mener à bien notre travail. Ensuite, nous exposons les résultats liés à nos différentes questions de recherche dans la section 5 avec discussion des résultats. Et enfin, dans la dernière section, nous donnons notre conclusion à la suite de toutes nos recherches et observations pour les pistes non explorées.

Chapitre 2

Concepts de bases et définitions

2.1 Introduction

Le clustering, ou segmentation en grappes, est une technique d'apprentissage non supervisé en machine learning et en analyse de données qui vise à regrouper des objets similaires en ensembles appelés clusters (ou grappes). Les objets au sein d'un même cluster sont plus semblables entre eux qu'avec ceux des autres clusters. Le clustering est utilisé pour découvrir des structures sous-jacentes dans des données sans étiquettes préalables [1].

Le but des algorithmes de clustering est de donner un sens aux données et d'extraire de la valeur à partir de grandes quantités de données structurées et non structurées [2]. Ces algorithmes permettent de séparer les données en fonction de leurs propriétés ou fonctionnalités et de les regrouper dans différents clusters en fonction de leurs ressemblances.

2.2 Concepts clés du clustering

- **L'apprentissage non-supervisé** : contrairement à l'apprentissage supervisé, où le modèle est formé sur des données étiquetées, le clustering ne nécessite pas de labels. L'objectif est de trouver une structure naturelle dans les données.
- **La similitude et la distance** : les mesures de similitude ou de distance entre les objets (comme la distance euclidienne, la distance de Manhattan, ou la similarité cosinus) jouent un rôle crucial dans le clustering. Ces mesures déterminent à quel point

deux objets sont similaires ou différents.

- **Les clusters** : un cluster est un groupe d'objets similaires. Les objets dans un cluster partagent des caractéristiques communes et sont distincts des objets des autres clusters.

2.3 Types de clustering

Les différents types de clustering se regroupent communément en deux grands ensembles qui sont : le hard clustering ou clustering strict et le fuzzy clustering ou clustering flou.

Le clustering strict est une méthode où chaque point de données appartient exclusivement à un seul cluster. Il affecte chaque point de données à un seul cluster sans ambiguïté. Dans le domaine particulier de la segmentation d'image, il reste largement utilisé en raison de sa simplicité d'implémentation et de compréhension, de l'interprétation simple des résultats, sa disponibilité dans de nombreuses bibliothèques de programmation et de sa rapidité. Cependant, bien qu'utile dans certaines applications, il présente des limitations importantes pour la segmentation d'images médicales en raison de sa sensibilité au bruit, de son incapacité à gérer l'incertitude et les chevauchements, et de son manque de prise en compte des informations spatiales qui peuvent conduire à des segmentations irréalistes. Dans le clustering strict, nous retrouvons :

- **Le clustering partitif (Partitioning)[3]** : K-means sépare les données en "k" clusters en minimisant la variance intra-cluster et les K-medoids (similaire à K-means, mais utilise des points de données réels comme centres de clusters (médoïdes) pour être plus robuste aux valeurs aberrantes).
- **Le clustering hiérarchique [5]** :
 - **Agrégeant (Agglomerative)** qui commence avec chaque point comme un cluster séparé et fusionne les clusters les plus

proches jusqu'à ce qu'il n'y ait plus qu'un seul cluster.

- **Divisant (Divisive)** commençant avec tous les points dans un seul cluster et divisant les clusters jusqu'à ce que chaque point soit dans son propre cluster.

— **Le clustering basé sur la densité [5] :**

- **DBSCAN (Density-Based Spatial Clustering of Applications with Noise)** : regroupe les points denses ensemble et identifie les valeurs aberrantes comme des points faiblement connectés.
- **OPTICS (Ordering Points To Identify the Clustering Structure)** : une extension de DBSCAN qui gère mieux les variations de densité. Elle ordonne les points pour identifier la structure de regroupement.
- **Clustering basé sur des modèles EM (Expectation-Maximization)** : utilise des modèles statistiques comme les mélanges gaussiens pour modéliser les données et allouer les points de données à différents clusters basés sur la probabilité.

Le deuxième groupe principal, à savoir le clustering flou, comprend la méthode Fuzzy c-means qui permet aux points de données d'appartenir à plusieurs clusters avec des degrés différents d'appartenance, contrairement aux méthodes de clustering strictes.

L'illustration de cette différence est représentée dans le schéma (2.1) et le tableau (2.1) :

2.3.1 Domaines d'applications

Les algorithmes de clustering ont plusieurs applications dans différents secteurs, à savoir :

— **Analyse de clients en marketing [3]** : segmentation de clients

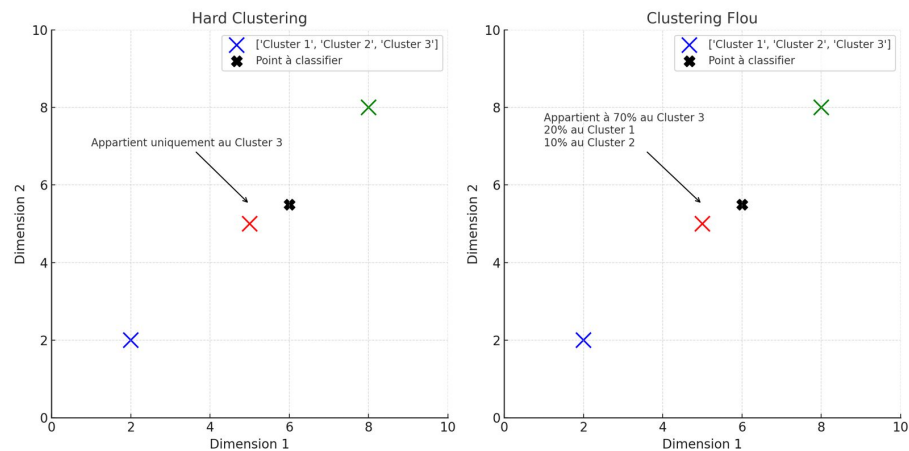


FIGURE 2.1 – Exemple visuel de clustering strict vs clustering flou

Caractéristiques	Clustering strict	Clustering flou
Assignation des Points	Unique (un seul cluster)	Multiple (plusieurs clusters avec degrés d'appartenance)
Méthodes Principales	K-means, K-medoids, Clustering hiérarchique	Fuzzy C-means
Gestion de l'Incertitude	Pas de gestion de l'incertitude	Gestion de l'incertitude et des chevauchements
Sensibilité au Bruit	Sensible au bruit et aux outliers	Plus robuste au bruit et aux outliers
Interprétabilité	Simple et claire	Plus complexe mais plus flexible
Complexité	Moins complexe	Plus complexe

TABLE 2.1 – Clustering strict vs Clustering flou

pour un marketing ciblé. Ces algorithmes peuvent regrouper les personnes ayant des caractéristiques similaires et analyser si elles achèteront votre produit. Ce groupage peut aider les entreprises à effectuer des tests afin de déterminer ce qu'elles doivent faire pour améliorer leurs ventes.

- **Analyse de données biologiques [4]** : groupement de gènes ou de protéines ayant des fonctions similaires aidant ainsi à comprendre les modèles d'expression génique ou à identifier des groupes fonctionnels.
- **Image et vidéo** : segmentation d'images en régions pour la reconnaissance d'objets ou le traitement d'images médicales. Les

algorithmes de regroupement ont été largement utilisés dans l'analyse d'images médicales pour des tâches telles que la segmentation, la classification et l'extraction de caractéristiques.

- **Systèmes de recommandation de contenu** : les plateformes de streaming ou de contenu en ligne utilisent le clustering pour regrouper des utilisateurs avec des préférences similaires, fournissant ainsi des recommandations de contenu personnalisées.
- **Classification automatique de documents** : dans le domaine du traitement du langage naturel, le clustering peut être utilisé pour regrouper des documents similaires, facilitant ainsi la classification automatique de contenus textuels.
- **Détection d'anomalies** : le clustering est utilisé pour identifier des comportements ou des observations inhabituels au sein d'un ensemble de données. Cela trouve des applications dans la détection de fraudes, la surveillance de la qualité des processus industriels, etc.
- **Cybersécurité[3]** : détection d'activités suspectes et de comportements anormaux dans les données de trafic réseau.

2.4 La logique floue

2.4.1 Définition

La logique floue, introduite par Lotfi Zadeh en 1965, est une extension de la logique classique destinée à gérer l'incertitude et l'imprécision. Contrairement à la logique binaire classique où une affirmation est soit vraie (1) soit fausse (0), la logique floue permet de modéliser des degrés de vérité dans un intervalle continu de $[0,1]$. Cette approche se rapproche davantage de la manière dont les humains raisonnent dans des situations où les frontières entre vrai et faux sont floues.

Un exemple courant de logique floue est le concept de température. Alors que la logique classique catégoriserait une température en

"chaud" ou "froid", la logique floue permet d'affirmer qu'une température est "60% chaud et 40% froid". Cette souplesse est particulièrement utile dans des systèmes où l'incertitude ou l'ambiguïté jouent un rôle important (2.2).

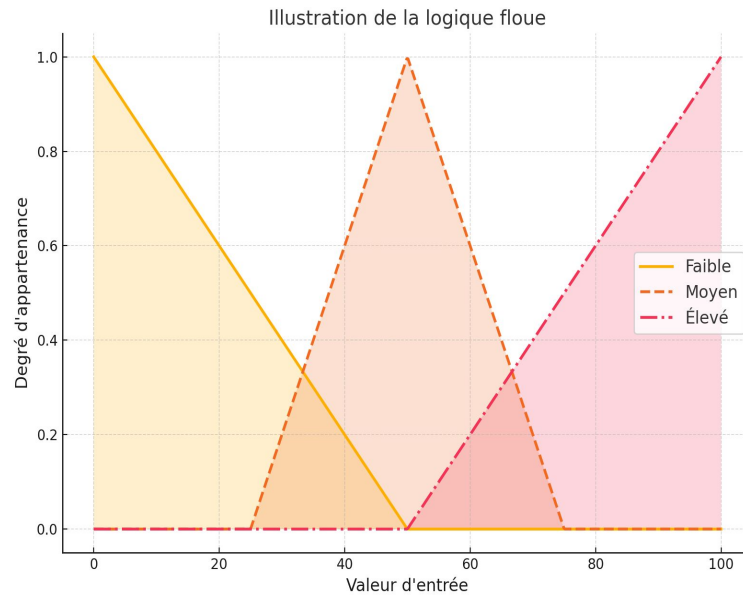


FIGURE 2.2 – Graphique d'illustration de la logique floue

2.4.2 Concepts

La logique floue repose sur trois concepts principaux :

- **Ensembles flous :** Contrairement aux ensembles classiques, un élément peut appartenir à un ensemble flou avec un degré d'appartenance compris entre 0 et 1.
- **Fonctions d'appartenance :** Elles définissent le degré auquel un élément appartient à un ensemble flou.
- **Opérations floues :** Des opérateurs tels que l'intersection (ET), l'union (OU), et la négation (NON) sont adaptés pour fonctionner avec des valeurs floues.

La logique floue, avec sa capacité à représenter et manipuler des informations imprécises ou ambiguës, constitue une base théorique es-

sentielle pour de nombreuses méthodes d'analyse, dont le clustering flou. En s'appuyant sur les principes de la logique floue, le clustering flou permet de regrouper des données tout en tenant compte de l'incertitude inhérente à leur classification. Cette approche reflète la nature floue et continue de nombreux phénomènes dans le monde réel, où les frontières entre catégories sont souvent imprécises. Le Fuzzy c-means, une méthode emblématique du clustering flou, applique ces concepts pour offrir une classification flexible et adaptée aux données complexes.

2.5 Le clustering flou

Le clustering flou, également connu sous le nom de fuzzy clustering, est une technique d'analyse de données qui permet à chaque point de données d'appartenir à plusieurs clusters avec différents degrés d'appartenance. Contrairement au hard clustering, le clustering flou offre une approche plus flexible et plus réaliste pour traiter les données pour lesquelles les frontières entre les groupes ne sont pas clairement définies.

1. Les concepts de bases du clustering flou

- **Le degré d'appartenance** : Chaque point de données possède un degré d'appartenance à chaque cluster, représenté par un nombre entre 0 et 1. La somme des degrés d'appartenance d'un point de données à tous les clusters est égale à 1.
- **La fonction objective** : Le clustering flou minimise une fonction objective qui prend en compte les degrés d'appartenance et les distances entre les points de données et les centres de clusters.

2. L'algorithme FCM

La méthode FCM est un algorithme largement connu et exploré dans plusieurs domaines, dont la segmentation d'image.

Introduit en 1973 par Dunn et perfectionné en 1981 par Bezdek [74], c'est un algorithme de regroupement souple qui calcule la probabilité d'appartenance d'un point à un groupe de points présentant des similitudes significatives.

Dans cet algorithme, les calculs de distances sont utilisés pour mesurer la similarité entre les points de données afin de déterminer la probabilité qu'un point de données appartienne à un groupe. L'algorithme traditionnel repose sur le calcul de la distance euclidienne.

La distance euclidienne entre deux vecteurs x et y est calculée par la formule suivante :

$$d(x, y) = \sqrt{\sum_{p=1}^d (x_p - y_p)^2} \quad (2.1)$$

Bien que la distance euclidienne soit optimisée pour détecter les grappes structurales sphériques, des études [48] montrent qu'elle ne permet pas de réaliser un regroupement précis avec des données de grande dimension ou non sphériques.

L'objectif de FCM est de diviser l'espace vectoriel des points de données en plusieurs sous-espaces en fonction d'une mesure de distance.

3. Fondements théoriques du FCM

Le FCM est une technique de clustering flou qui permet à chaque point de données d'avoir un degré d'appartenance à plusieurs clusters déterminés par la minimisation de la fonction objective suivante :

$$J_m = \sum_{i=1}^N \sum_{j=1}^c u_{ij}^m \|x_i - c_j\|^2 \quad (2.2)$$

Où :

— N est le nombre de points de données,

-
- c est le nombre de clusters,
 - x_i les pixels de l'image,
 - u_{ij} est le degré d'appartenance du point de données i au cluster j ,
 - m est un paramètre de pondération (généralement $m > 1$).

Le degré d'appartenance [6] est défini par l'équation (2.3) :

$$u_{ij}^m = \frac{1}{\sum_{k=1}^c \left(\frac{x_i - c_j}{x_i - c_k} \right)^{\frac{2}{m-1}}} \quad (2.3)$$

Où :

- c est le centroïde du cluster j ,
- m est le degré de flou,
- u est le degré d'appartenance du point de données i au cluster j .

Dans la classification floue, le centroïde d'une grappe est la moyenne de tous les points pondérés par leur degré d'appartenance à la grappe. Il est illustré dans l'équation (2.4) :

$$C_j = \frac{\sum_{xinC_j}^c u_{ij} X}{\sum_{xinC_j}^c u_{ij}} \quad (2.4)$$

Où :

- C_j est le centroïde du cluster j ,
- u_{ij} est le degré d'appartenance du point de données i au cluster j .

L'algorithme alterne entre la mise à jour des centres de grappes (centroïdes) et des degrés d'appartenance jusqu'à la convergence.

Il peut être résumé par les étapes suivantes (1) :

Algorithm 1 Étapes de FCM

```

0: Input
0: Etape 1 : Spécifier un nombre de grappes  $k$ , l'index de flou  $m$ , le nombre maximum
    d'itération  $t_{max}$ .
0: Etape 2 : Attribuer aléatoirement à chaque point des coefficients d'appartenance aux
    grappes.
0: Etape 3 :
0: while  $t \leq t_{max}$  do
0:   Calculer le centroïde pour chaque groupe, en utilisant la formule ci-dessus.
0:   Pour chaque point, calculez ses coefficients d'appartenance aux grappes.
0: end while
0: Output centre de clusters  $c$  et degré d'appartenance  $u.$  =0
  
```

Grâce à sa flexibilité, l'algorithme a apporté de nouvelles solutions et touché à des domaines variés comme :

- **La construction de modèles** qui traite de la construction et de la classification des structures dans le but d'interpréter les structures syntaxiques (termes, formules, démonstrations...) dans des structures mathématiques (ensemble des entiers naturels, groupes, univers...) de façon à leur associer des concepts de nature sémantique (comme le sens ou la vérité)[7].
- **Analyse de données** (aussi appelée analyse exploratoire des données ou AED) est une famille de méthodes statistiques dont les principales caractéristiques sont d'être multidimensionnelles et descriptives. Elle permet de traiter un nombre très important de données et de dégager les aspects les plus intéressants de la structure de celles-ci [8].
- **La classification des données** est une méthode permettant de définir et de catégoriser les fichiers et autres informations commerciales critiques. Elle est principalement utilisée dans les grandes entreprises pour mettre en place des systèmes de sécurité respectant des directives de conformité strictes, mais elle peut également être utilisée dans les petits environnements. L'utilisation la plus importante de la classification des données est la compréhension de la sensibilité des informations

stockées, afin de pouvoir mettre en place les outils de cybersécurité, les contrôles d'accès et la surveillance appropriés. Elle catégorise des actifs de données en fonction de la sensibilité de l'information. En classifiant les données, les organisations peuvent déterminer deux choses essentielles [11] :

- Qui doit être autorisé à y accéder ?
- Quelles politiques de protection appliquer lors de leur stockage et de leur transfert ?

La classification peut également aider à déterminer les normes réglementaires applicables pour protéger les données. Globalement, la classification des données aide les organisations à mieux gérer leurs données en matière de confidentialité, de conformité et de cybersécurité.

- **La segmentation d'image** qui est une opération de traitement d'images consistant à détecter et rassembler les pixels suivant des critères, notamment d'intensité ou spatiaux, l'image apparaissant ainsi formée de régions uniformes. La segmentation peut par exemple montrer les objets en les distinguant du fond avec netteté. Dans les cas où les critères divisent les pixels en deux ensembles, le traitement est une binarisation. La segmentation est une étape primordiale en traitement d'image [12].
- **La reconnaissance des formes** (ou parfois reconnaissance de motifs) est un ensemble de techniques et méthodes visant à identifier des régularités informatiques à partir de données brutes afin de prendre une décision dépendant de la catégorie attribuée à ce motif. On considère que c'est une branche de l'intelligence artificielle qui fait largement appel aux techniques d'apprentissage automatique et aux statistiques [9].

L'algorithme est structuré et fonctionne de la manière suivante (2) pour la segmentation d'image :

Algorithm 2 Étapes de FCM pour la segmentation

```

0: Input
0: Initialisation des paramètres
0:  $C$  : nombre de clusters
0:  $m$  : degré de flou
0:  $\epsilon$  : l'erreur
0: Initialisation aléatoire du nombre de clusters
0: Début de l'itération  $k = 1$ 
0: while  $\|U_{(k+1)} - U_{(k)}\| \leq \epsilon$  do
0:   Calcul du degré d'appartenance  $u_{ij}$  grâce au centre de clusters  $c_i$ 
0:   Calcul de la matrice d'appartenance  $U_k$ 
0:   Mise à jour des centroïdes  $c_i$ 
0: end while
0: Output  $c_{ij} = 0$ 
  
```

2.5.1 Avantages et inconvénients de l'algorithme FCM

1. Avantages

- **Flexibilité** : permet aux points de données d'appartenir partiellement à plusieurs clusters, ce qui est utile pour les données avec des frontières floues entre les groupes.
- **Gestion des Chevauchements** : peut gérer efficacement les chevauchements entre les clusters, ce qui est particulièrement utile dans des applications comme la segmentation d'images médicales où les tissus peuvent se chevaucher.
- **Robustesse** : plus robuste aux variations d'intensité et aux artefacts par rapport aux méthodes de clustering strict.

2. Inconvénients

- **Complexité computationnelle** : plus complexe que le hard clustering en raison de la nécessité de calculer et de mettre à jour les degrés d'appartenance.
- **Sensibilité aux paramètres** : la performance de l'algorithme dépend de la sélection appropriée du nombre de clusters.

ters et du paramètre de pondération m .

- **Interprétation** : les résultats peuvent être plus difficiles à interpréter que ceux du hard clustering, car les points de données peuvent appartenir à plusieurs clusters simultanément.

2.5.2 Applications de FCM dans la segmentation d'images médicales

La segmentation des images médicales est cruciale pour de nombreuses applications, allant du diagnostic assisté par ordinateur à la planification chirurgicale. FCM est une méthode de clustering largement utilisée à cet effet. Sa flexibilité permet la segmentation de différents types d'images médicales.

- **Segmentation des images IRM** : Les images par résonance magnétique (IRM)(2.3) sont couramment utilisées pour l'examen des tissus mous dans le corps humain. Le FCM a été appliqué pour segmenter les tissus cérébraux (matière grise, matière blanche et liquide céphalorachidien) avec succès, permettant de mieux identifier les anomalies telles que les tumeurs [13].




Image originale

Image segmentée

FIGURE 2.3 – Image d'IRM

- **Segmentation des Scans CT** : Les tomodensitométries (2.4) sont utilisées pour visualiser les structures osseuses et certains tissus mous. Le FCM aide à distinguer les différentes densités de tissus, ce qui est essentiel pour la détection des lésions pulmo-

naires, des kystes et des fractures osseuses [14].




FIGURE 2.4 – Image de Scanner

- **Segmentation des Images Echographiques :** les images échographiques (2.5) sont souvent bruitées, rendant la segmentation difficile. Le FCM en combinaison avec des techniques de filtrage spatial permet de segmenter les tissus et les structures internes avec une précision améliorée [15].




FIGURE 2.5 – Image d'échographie

2.6 Quelques optimisations

1. L'optimisation par essaim de particules(PSO)

Le PSO [16] est attribué à l'origine à Kennedy, Eberhart et Shi et a d'abord été conçu pour simuler le comportement social,

comme une représentation stylisée du mouvement des organismes dans une volée d'oiseaux ou un banc de poissons. L'algorithme a été simplifié et il a été observé qu'il effectuait une optimisation. Une variante de base de l'algorithme PSO fonctionne avec une population (appelée essaim) de solutions candidates (appelées particules), qui se déplacent dans l'espace de recherche selon quelques formules simples. Les mouvements des particules sont guidés par leur propre position la plus connue dans l'espace de recherche ainsi que par la position la plus connue de l'ensemble de l'essaim. Lorsque des positions améliorées sont découvertes, elles viennent alors guider les mouvements de l'essaim. Le processus est répété et l'on espère ainsi, sans toutefois le garantir, qu'une solution satisfaisante finira par être découverte.

2. L'algorithme génétique

Introduite pour la première fois en 1975 par Holland, il appartient à la famille des algorithmes évolutionnaires. Son but est d'obtenir une solution approximative à un problème d'optimisation, lorsqu'il n'existe pas de méthode exacte (ou que la solution est inconnue) pour le résoudre en un temps raisonnable. Les algorithmes génétiques (2.6) utilisent la notion de sélection naturelle et l'appliquent à une population de solutions potentielles au problème donné [17].

2.7 Conclusion

FCM est un algorithme puissant et flexible pour la segmentation d'images médicales. Ses capacités à gérer l'incertitude et les chevauchements le rendent particulièrement adapté aux applications médicales. Cependant, des améliorations continues sont nécessaires pour surmonter ses limitations, telles que la sensibilité au bruit, aux valeurs aberrantes et la complexité computationnelle. Les développements récents et les approches hybrides montrent des promesses significatives pour améliorer la précision et l'efficacité de la segmentation des images

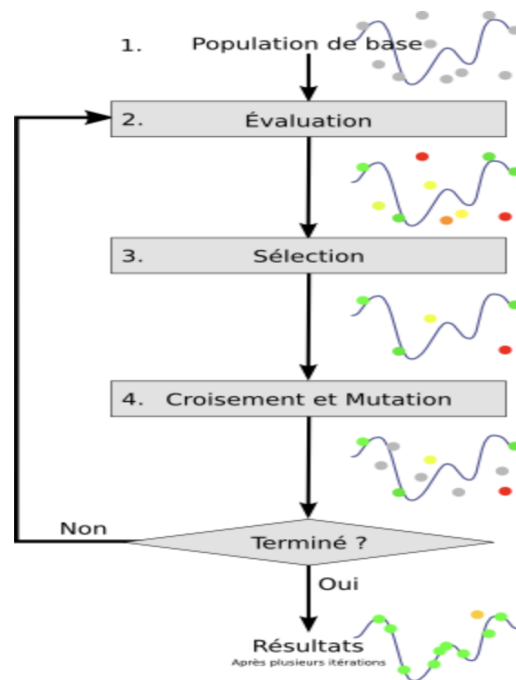


FIGURE 2.6 – Schéma récapitulatif de l'algorithme génétique

médicales.

Dans ce cadre, nous avons dressé une étude sur l'état de l'art de la recherche afin de mettre en évidence les pistes qui ont été élaborées jusqu'à date dans le domaine, et dans le but de dégager les limites de ces méthodes et de trouver de nouvelles pistes d'amélioration pour cet algorithme très prometteur dans le domaine important de la segmentation d'image médicale.

Chapitre 3

État de l'art

3.1 Introduction

La technologie de l'imagerie médicale qui connaît actuellement une révolution majeure joue un rôle crucial dans le diagnostic des maladies humaines et le diagnostic assisté par ordinateur [18]. Les méthodes classiques d'étude de l'imagerie médicale nécessitent beaucoup de main-d'œuvre et sont donc coûteuses en termes de ressources de soins de santé [19]. Ces dernières années, l'accent a été mis sur la création de machines et d'algorithmes pour simplifier l'acquisition et l'analyse des images médicales. Cette avancée permet aux médecins de faire des choix plus précis et plus éclairés concernant le diagnostic et le traitement des maladies. L'utilisation des IRM, des échographies et des scans pour détecter et évaluer l'ampleur des tumeurs et cancers est un élément crucial pour les traiter efficacement. En effet, lorsque ces maladies sont détectées précocement, le taux de survie augmente fortement [48]. Pour déterminer avec précision la taille et l'étendue des tumeurs ou anomalies, les images médicales doivent être segmentées afin de séparer les régions affectées des régions saines. Ce processus nécessite un haut degré de précision pour éviter de perdre des données essentielles. Plusieurs techniques telles que l'intelligence artificielle (IA), les méthodes de seuillage, les méthodes de regroupement, la détection des contours et l'apprentissage automatique sont connues et expérimentées dans plusieurs études.[20].

3.2 L'intelligence artificielle (IA) dans le domaine médical

L'IA est un ensemble de théories et de techniques visant à réaliser des machines capables de simuler l'intelligence humaine [21]. Elle s'est introduite au fil des années dans des domaines variés, dont le domaine médical.

Dans leur revue systématique, Omar A. et al [22] nous font part des bénéfices, défis, méthodes et fonctionnalités qui font de l'IA une valeur sûre dans le domaine médical. En effet, l'introduction de l'IA dans ce domaine a eu un impact très bénéfique à plusieurs échelles, à savoir la catégorie individuelle (pour le patient et le professionnel de santé) avec la prise de décision automatisée, le meilleur suivi des patients, le diagnostic précoce, la simplification des processus, la catégorie organisationnelle avec l'amélioration du flux de travail, la réduction des coûts, la détection des fraudes, le gain de temps, l'optimisation des ressources, la formation des professionnels, la disponibilité et le partage des données. Quant aux défis qui demeurent, on retrouve : la sécurité des patients, l'intégration des données, le respect de la vie privée et des questions juridiques, l'intégration des données à l'échelle de l'industrie. Les méthodes passent par des traitements multimédias et des traitements des données textuelles au travers de plusieurs technologies et algorithmes. Les technologies récentes d'IA englobent le

Big Data, les applications d'apprentissage automatique et les robots qui sont utilisés pour surveiller, détecter et mesurer les risques et les avantages dans le secteur des soins de santé .

Les bénéfices de l'IA pour les patients sont directement liés à ses fonctionnalités pertinentes dans les catégories du diagnostic, du traitement, de la consultation et de la surveillance de la santé pour l'autogestion des maladies chroniques. De même, en ce qui concerne les fonctionnalités soutenant les organisations médicales, elle optimise les processus médicaux qui conduisent à la prise de décision clinique et la recherche sur l'impact de l'IA sur la prise de décision qui continue d'évoluer dans le secteur des soins de santé. Ses fonctionnalités les plus importantes qui soutiennent le secteur des soins de santé se trouvent dans les domaines de l'imagerie médicale et de la chirurgie robotique.

Ces domaines constituent de nouvelles innovations dans ce secteur et l'IA soutient l'innovation en termes d'amélioration des capacités de recherche et de développement (Gumbs et al., 2021). Un de ses autres domaines de fonctionnalité est la collecte autonome de données, qui favorisera la capture de points de données significatifs, améliorant ainsi la validité et la confiance des résultats des décisions prises par l'IA dans les systèmes de soins de santé [22].

3.3 L'IA et la segmentation d'image médicale

En raison de progrès techniques révolutionnaires et de résultats expérimentaux impressionnants de l'intelligence artificielle dans de nombreux domaines, notamment dans l'analyse et le traitement d'images, de nombreux travaux ont été menés et publiés dans le but de transférer le potentiel de l'IA à des applications cliniques.

Des études récentes sur l'intelligence artificielle et l'apprentissage automatique pour l'imagerie médicale par Barragán-Montero, A. et al [23] ont permis d'établir les différentes méthodes de l'IA utilisées dans le domaine de l'imagerie médicale. Nous y retrouvons :

- **Les Forêts aléatoire ou Random forests (RFs)** qui utilisent un ensemble d'arbres de décision binaires non corrélés (modèles d'apprentissage multiples) pour trouver le meilleur modèle d'apprentissage. Ses premières applications remontent à une dizaine d'années et concernaient la localisation d'organes et la délimitation. Depuis, elles ont été appliquées à de nombreuses tâches, notamment la détection et la localisation, la segmentation et la prédiction basée sur l'image. Pour certaines applications spécifiques, elles ont démontré une amélioration des performances par rapport à d'autres méthodes classiques du Machine Learning. Toutefois, de nombreux autres travaux dans le domaine médical ont également comparé la précision des RFs, à celle de classificateurs Machine Learning (ML) plus complexes ou plus simples, et il est bien connu que leurs performances peuvent varier selon les applications et même selon les ensembles de données au sein

d'une même application. Il est donc difficile de conclure à la supériorité absolue de l'algorithme RFs sur les autres classificateurs ML [23].

- **Les réseaux de neurones convolutionnels ou Convolutional neural networks (CNNs)** qui s'inspirent du système visuel humain et exploitent la disposition spatiale des données dans les images. Leur remarquable capacité à détecter les représentations hiérarchiques des données a fait des CNNs l'architecture la plus populaire pour les applications actuelles de traitement des images médicales. Ce système permet d'extraire d'abord des caractéristiques simples, comme des arêtes, dans les couches les plus profondes, qui sont ensuite combinées et affinées en caractéristiques hiérarchiques plus riches et plus complexes, comme des organes complets. Les réseaux entièrement convolutifs (FCN) ont été proposés pour effectuer efficacement des tâches d'image à image telles que la segmentation, la détection, la localisation, la classification, la segmentation et le débruitage. Il convient de noter que ces deux réseaux sont souvent utilisés de manière interchangeable [23].
- **Les Réseaux adversaires génératifs ou Generative adversarial networks (GANs)** qui sont des architectures populaires utilisées pour la modélisation générative. Jusqu'à présent, dans le domaine de l'imagerie médicale, les GANs ont été principalement appliqués à la génération d'images synthétiques pour l'augmentation des données et la traduction d'images multimodales (par exemple, RM vers CT, CBCT vers CT). De plus, ils pourraient être une excellente application pour les tâches d'assurance qualité en radio-oncologie, par exemple [23].

Les articles cités dans ce manuscrit nous apprennent qu'une partie importante de la recherche s'est jusqu'à présent concentrée sur la simple transposition des dernières avancées Machine Learning/Deep Learning (ML/DL) dans le domaine de la vision par ordinateur aux applications médicales, afin de démontrer le potentiel de ces méthodes et la faisabilité de leur utilisation pour améliorer la pratique clinique.

C'est le cas de certains des articles cités, comme les premières preuves de concept de l'utilisation des CNN pour la segmentation des organes et pour la prédiction de la dose pour les traitements de radiothérapie, ou l'utilisation des GANs pour la conversion entre les modalités d'image. D'autres méthodes comme les méthodes de segmentation ba-

sées sur l'intelligence artificielle sont également mentionnées par Hanane D. et al. [24]. Elles sont l'une des rares méthodes appliquées à la détection des tumeurs sur les images de thermogrammes mammaires.

3.4 Les architectures hybrides

Il existe également des architectures hybrides dans lesquelles les chercheurs ont utilisé la logique floue avec les algorithmes d'apprentissage profond. Par exemple, l'étude menée par Javad Hassannataj J. et al. [88] vise à améliorer le diagnostic de la maladie coronarienne (CAD) en intégrant le regroupement FCM à un réseau neuronal profond (DNN), créant ainsi un modèle hybride appelé FCM-DNN. Dans ce modèle, le regroupement FCM est utilisé pour identifier des structures cachées dans les données et attribuer des degrés d'appartenance à chaque point, reflétant l'incertitude et les variations dans les données cliniques. Ces sorties floues servent ensuite d'entrée pour le réseau neuronal profond, qui apprend des caractéristiques complexes et affine la classification ou la prédiction finale. Cette architecture tire parti de la capacité de FCM à gérer des données imprécises et de la puissance des DNN pour capturer des représentations hiérarchiques.

Les résultats obtenus indiquent que le modèle FCM-DNN a atteint une précision de 99,91% en spécifiant 10 clusters (5 pour les sujets sains et 5 pour les sujets malades) grâce à une validation croisée à 10 volets. Cette performance surpasse celle des modèles traditionnels de réseau neuronal (NN) et de réseau neuronal profond (DNN), qui ont respectivement atteint des précisions de 92,18% et 99,63%. Ces résultats suggèrent que l'intégration du clustering flou avec des réseaux neuronaux profonds peut améliorer significativement la précision du diagnostic de la CAD.

3.5 Les techniques de segmentation d'image médicale

Ces dernières années, la segmentation des images médicales a connu des avancées extraordinaires dans le domaine de la recherche. Plusieurs méthodes de segmentation diverses ont alors pu voir le jour.

Kaushal C. et al. [27] font état dans leur étude des techniques de segmentation d'images médicales. Nous avons la technique de segmentation par seuil qui se subdivise en trois méthodes à savoir : la méthode globale, la méthode variable et la méthode multiple. Les méthodes basées sur l'histogramme, encore appelées méthodes du seuillage, sont utilisées pour segmenter une image en plusieurs classes. En effet, à partir d'un histogramme qui décrit la fréquence d'apparition des niveaux de gris des pixels dans une image, on va extraire les classes qui sont associées aux pics de l'histogramme. Il y a de très nombreuses méthodes de seuillage dont les principaux avantages sont : le caractère global de la méthode, la simplicité et la rapidité des calculs. Il est à noter que ces méthodes sont généralement utilisées pour la segmentation en deux classes (i.e. génération d'une image binaire). Quand il s'agit d'une segmentation multi-classes, les résultats sont rarement garantis. Nous pouvons aussi citer comme inconvénients que ces méthodes ne prennent pas en compte les voisinages des pixels et que des images qui ne diffèrent que par une permutation des pixels auront le même histogramme [28].

De plus, la présence de bruit et de limites obscures influence la segmentation par seuillage [27].

Dans leur revue sur les algorithmes de segmentation des images médicales, Ramesh K.K.D. et al. [29] évoquent les différentes méthodes basées sur les régions pour la segmentation d'image à savoir : le grossissement des régions qui est une méthode adaptative, l'approche par division et fusion de régions permettant d'éliminer les artéfacts à forte récurrence et l'approche par bassin versant. Les méthodes de croissance de régions sont des méthodes ascendantes et locales. L'idée de ces méthodes est simple : faire croître chaque région autour d'un pixel de départ qu'on appelle un point d'amorce (seed) en y agrégeant les pixels du voisinage qui satisfont un critère d'homogénéité i.e. on définit

un seuil de similarité à partir duquel on considère que les pixels sont similaires. Le point d'amorce peut être choisi soit par un humain, soit de manière automatique en évitant les zones de fort contraste où on a un gradient important. Les avantages de ces méthodes sont la facilité de mise en œuvre et la rapidité au moment de l'exécution. Par contre, leur inconvénient est le fait que la méthode soit locale (la méthode basée sur les pixels), peu stable, très sensible au bruit, au gradient, à la texture et à l'ordre du traitement des pixels.

La technique de segmentation par détection des bords est abordée dans les travaux de Bhawna D. et al. [25]. Elle consiste à identifier les bords de l'image, puis les bords sont connectés les uns aux autres pour construire la limite de l'image. La détection des contours est une méthode permettant de déterminer les frontières des régions (les contours des objets) qui viennent de la réflectance des objets comme l'ombre, la texture ou des bords des objets. Ces méthodes servent à déterminer les pixels des frontières, qui engendrent des discontinuités ou une variation rapide des caractéristiques. Pour les détecter, il existe deux approches qui sont : la technique de détection et fermeture de contours et la technique de contours déformables ou actifs (snakes). Pour localiser les pixels de contours, la technique de détection et fermeture de contours ou la technique basée sur les dérivées discrètes de la fonction de niveau de gris sont basées sur l'information de gradient (qui est un vecteur déterminé par son amplitude G et sa direction Ω). Les inconvénients de ces différentes méthodes sont qu'elles sont locales (basées sur le pixel), complexes et sensibles au bruit. De plus, les résultats sont parfois faux et le temps de calcul est long.

3.6 Le clustering et la segmentation médicale

Les algorithmes de regroupement ont été largement utilisés dans l'analyse d'images pour des tâches telles que la segmentation, la classification et l'extraction de caractéristiques. Plusieurs algorithmes de regroupement sont couramment utilisés dans l'analyse d'images.

Hanane D. et al. [24] dans leur étude décrivent les algorithmes

de regroupement comme étant très efficaces mais encore confrontés à des limitations comme la sensibilité aux valeurs initiales. L'idée de ces méthodes est de définir des groupes de pixels (clusters) de telle sorte que chaque groupe minimise l'erreur intra-classe (la différence entre les pixels) afin d'obtenir un groupe le plus homogène possible. Cela est équivalent à maximiser l'erreur inter-classes (la différence entre les groupes) afin d'obtenir des groupes (clusters) bien différenciés. Les avantages de ces méthodes sont en général leurs caractères globaux et locaux, ainsi que leur simplicité d'implémentation. Il y a des méthodes simples et rapides, comme les nuées dynamiques (Hartigan Wong, 1979) [24] et d'autres qui fournissent des segmentations de meilleure qualité comme les méthodes basées sur les champs de Markov cachés présentées par Anfel M. et al. [28].

Le regroupement de données homogènes en grappes en fonction de critères analogiques est appelé « clustering ». Le « K-means » est l'algorithme fondamental de segmentation en grappes dans lequel les composants de l'ensemble de données n'appartiennent qu'à une seule grappe à la fois. L'approche de clustering doux (FCM) dans laquelle le pixel peut avoir une place dans plus d'un groupe et la valeur de la fonction de communauté floue est le pouvoir décisif pour s'adapter à un pixel dans le groupe, et la valeur se situe dans une fourchette de 0 à 1 [27].

K-means est l'une des plus répandues dans les méthodes de clustering au vu de sa simplicité de calcul et de son efficacité de segmentation. Cependant, il reste limité par le principe du clustering strict qui influence énormément l'extraction des régions d'intérêts et les résultats de segmentations. L'algorithme FCM traditionnel est basé sur la distance euclidienne. Bien que la distance euclidienne soit optimisée pour détecter les grappes structurelles sphériques, des études montrent qu'elle ne permet pas de calculer des grappes précises avec des données de grande dimension ou non sphériques. Ramesh K.K.D. et al.

[29] font également mention de quelques méthodes d'optimisation du FCM sans s'étayer sur les détails de ses optimisations. Nous avons par exemple Kernelized FCM (KFCM), T2FCM (TYPE-II FCM), IFCM

(INTUITIONIST FCM), Fuzzy based artificial bee colony (FABC). Toutes ces optimisations ont permis l'amélioration du FCM dans la segmentation d'image médicale.

Une brève revue des algorithmes de segmentation d'images médicales basés sur le regroupement rédigée par Chetna K. et al. [27] nous fait part des techniques de clustering expérimentées sur diverses bases de données (MRI Data Bank, IRIS, BRATS , Harvard Whole Dataset) et utilisées dans des diagnostics médicaux précis à savoir : la segmentation des tumeurs cérébrales avec des méthodes comme K-means, Improved K-means, FCM, la segmentation des lésions cérébrales en utilisant le concept de réseaux neuronaux entièrement profonds (DFCNN), avec des réseaux de neurones profonds (DNN) et FCM, la segmentation des cellules sanguines leucémiques grâce aux méthodes K-means, FCM, les champs aléatoires de Markov cachés (HMRF) et la segmentation des nodules pulmonaires à partir de plusieurs classifieurs comme les K-voisins les plus proches (K-NN), machine à vecteurs de support (SVM), multinomial de Bayes, descente de gradient stochastique, forêt aléatoire et perceptron multicouche (MLP).

3.7 Les défis de l'imagerie médicale

La segmentation des images médicales confronte les différentes méthodes citées plus haut à deux défis importants.

Premièrement, les images médicales peuvent être de nature complexe et contenir des régions d'intérêt qui se chevauchent. En effet, les algorithmes de regroupement s'appuient sur des méthodes de recherche locale pour trouver les centres des grappes. En conséquence, il y a un risque important de rencontrer des problèmes de minima locaux, ce qui peut amener l'algorithme à choisir des centres inappropriés, ce qui résultera par la suite à un regroupement sous-optimal.

Deuxièmement, dans la plupart des techniques de regroupement, les valeurs finales des grappes sont déterminées à l'aide de centres de départ prédéfinis. Cela peut conduire à des résultats de segmentation

imprécis, qui peuvent ne pas capturer complètement les caractéristiques sous-jacentes des images médicales analysées.

3.8 Conclusion

Notre état de l'art survole plusieurs approches de l'intelligence artificielle dans la segmentation d'image médicale avec les travaux d'améliorations de la segmentation à travers les méthodes des forêts aléatoires, les réseaux de neurones convolutifs et les réseaux adversaires génératifs. D'autres approches, comme les techniques de segmentation par seuil, les méthodes basées sur les régions de l'image, la segmentation par détection des bords, les méthodes de regroupement comme K-means et FCM.

Ces nombreuses méthodes développées pour la segmentation ont certes eu une incidence positive permettant un traitement moins coûteux et plus rapide, mais elles ne sont pas pour autant adaptées au traitement des images médicales complexes. Avec les études menées sur le clustering flou, nous avons pu observer une avancée positive sur les résultats de segmentation, comme la meilleure résistance au bruit et une meilleure prise en charge des chevauchements. Cependant, au vu du besoin d'un traitement plus précis des images médicales et des lacunes restantes répertoriées, la nécessité de poursuivre la recherche et le développement d'algorithmes de regroupement qui peuvent mieux répondre aux exigences spécifiques de l'analyse d'images médicales reste d'actualité.

Dans cette optique, notre étude répertorie les optimisations les plus pertinentes qui ont permis à l'algorithme flou FCM, qui est l'une des techniques de segmentation les plus efficaces [30], de dépasser les possibles limitations qui lui incombent pour une segmentation plus précise et fiable.

Chapitre 4

Méthodologie de recherche

4.1 Introduction

Les données recueillies précédemment nous ont permis d'élaborer un plan afin d'établir une revue globale de la littérature liée à l'utilisation de FCM dans la segmentation d'image médicale. Dans ce chapitre, nous faisons état des différentes étapes de notre méthodologie de recherche qui nous ont aidés à constituer une base de travail solide.

4.2 Questions de recherche

Le but de notre revue est d'établir l'étude la plus complète possible sur la méthode FCM dans le domaine de la segmentation d'images médicales. Nous voulons principalement établir une carte complète sur l'état de la recherche concernant les techniques d'optimisation les plus pertinentes répertoriées au cours des cinq dernières années qui ont permis de pallier les diverses limitations de l'algorithme. Ainsi, les différentes questions de recherche auxquelles nous souhaitons répondre sont :

- **Question 1 :** Quelles sont les optimisations et à quel niveau de l'algorithme sont-elles implémentées ?
- **Questions 2 :** Quels sont les avantages et les inconvénients de ces optimisations en termes de robustesse, d'efficacité de calculs et de précision lors du regroupement ?

Pour répondre à ces questions, nous effectuons une recherche à l'aide des mots-clés et des années sélectionnées pour trouver et sélectionner les articles que nous aurons à étudier. Ces articles, nombreux et variés, sont ensuite partiellement étudiés afin d'en identifier les mots-clés et les titres à partir desquels nous avons pu déterminer la potentielle pertinence pour notre étude. Ensuite, la lecture du titre nous a permis d'éliminer les doublons. Par la suite, nous nous sommes assurés que les articles identifiés sont pertinents et offrent des réponses aux questions de recherche en effectuant une évaluation de la qualité par une lecture diagonale du résumé, de la méthodologie de recherche et de la conclusion.

Par la suite, ces articles, après filtrage, ont été stockés par base de données de provenances dans des documents Excel et ordonnés par années de publication. En plus, nous extrayons après l'étude de chaque article les types d'optimisations et leur application dans l'algorithme FCM. Cette extraction nous a permis d'établir les différents niveaux d'optimisation qui seront le squelette de notre étude. À la suite de cette étape, nous avons regroupé tous les articles dans un document en fonction des niveaux d'optimisation.

Enfin, nous avons résumé les données pertinentes de chaque article grâce à des tableaux de données précises que nous avons nous-mêmes établis afin de répondre aux besoins de notre étude. Ces tableaux de données sont collectés dans un document Word et construits par les entêtes suivants : méthode d'optimisation, mode de fonctionnement et d'expérimentation, avantages, inconvénients et articles de référence.

Pour réduire autant que possible les biais, nous effectuons la recherche documentaire dans plusieurs bases de données pluridisciplinaires et recueillons un grand nombre d'articles, qui seront sujets à des études préliminaires.

Pour nous guider, nous avons eu recours aux étapes de sélection suivantes (4.1) :

- Identifier les mots-clés pour la recherche d'articles.

- Identifier les bases de données pour la recherche d'articles dans celles disponibles.
- Élaborer une requête de recherche et l'exécuter sur la base des mots-clés dans chaque base de données.
- Trier manuellement les résultats à partir de la lecture des mots-clés, du résumé et de la conclusion.
- Créer un document permettant de stocker tous les articles retenus pour notre étude.
- Définir les niveaux d'optimisation et ordonner les articles selon ces catégories définies.
- Lire et résumer les articles obtenus dans des tableaux de données. Ces tableaux ont pour entêtes respectives : Le nom de la méthode utilisée, le mode de fonctionnement, les avantages, les inconvénients, le(s) article(s) de références et leurs liens.
- Utiliser les données recueillies pour répondre à nos questions de recherches.
- Effectuer la rédaction de notre revue systématique.

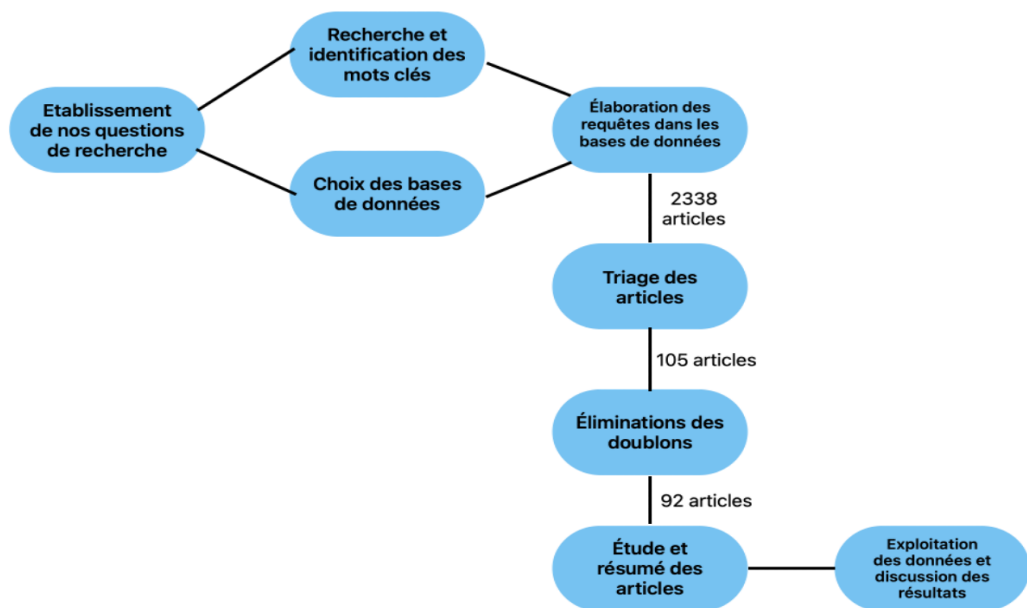


FIGURE 4.1 – Étapes de notre méthodologie de recherche

4.3 Les mots-clés

Pour répondre aux objectifs de notre recherche, nous identifions des mots-clés pertinents pour trouver des articles susceptibles de fournir des données permettant de répondre à nos questions de recherche.

Nous avons débuté par l'application des mots-clés **FuzzyANDc-means**. Nous avons ensuite rajouté les mots-clés **OptimisationANDSegmentationANDImageANDmédicale**. Cette recherche sur les différentes bases de données a permis de passer de **61 257** articles sur FCM à **2338** articles répondant plus ou moins aux requêtes que nous avons formulées. En plus de ces mots-clés, nous avons également rajouté les années ciblées par notre étude, à savoir entre **2019** et **2024**.

Nous lisons ensuite attentivement le titre et le résumé de chacune de ces études et déterminons si l'étude est susceptible de fournir des données pour répondre à nos questions de recherche. Après l'élimination des doublons, des articles qui ne répondaient pas à nos questions de recherche et des moins pertinents (avec des données insuffisantes ou peu explicitées) à l'aide de la lecture du titre, du résumé et de la conclusion, **76** articles finaux publiés entre **2019** et **2024** ont été retenus. Nous les avons par la suite triés et regroupés selon le type d'optimisation développé par chacun d'eux.

4.4 Les bases de données

Pour maximiser la couverture de notre étude sur FCM, nous avons sélectionné quatre bases de données d'articles scientifiques contenant des millions d'articles scientifiques divers et variés. Ces bases de données sont représentées dans le tableau (4.1). Ce tableau contient les colonnes suivantes : Nbrs articles FCM, Nbrs articles FCM&domaine médical et Nbrs articles étudiés.

Ces colonnes représentent respectivement :

- Le nombres d'articles que nous avons comptabilisé en recherchant **FuzzyANDc-means** dans les différentes bases de données.
- Le nombres d'articles obtenus après applications de tous les mots-clés et des dates ciblées par notre étude et explicités dans la

section 4.3.

- Le nombre d’articles utilisées dans notre revue systématique après lecture préliminaire du titre (pour l’élimination des doublons), du résumé, de l’introduction, de la méthodologie de recherche et des résultats de ces études (pour évaluer la pertinence dans notre revue).

Bibliothèques	Nbrs articles FCM	Nbrs articles FCM&domaine médical	Nbrs articles étu- diés
IEEE Xplore	8 537	53	15
EBSCO	4092	25	17
SPRINGERLINK	20000	1382	40
SCOPUS	4702	1197	10

TABLE 4.1 – Bases de données exploitées

4.5 Résultats

Nous avons **82** études retenues qui serviront à l’élaboration de notre revue systématique sur les approches algorithmiques du type FCM. Nous les avons classées en trois catégories d’optimisation, à savoir : les optimisations au niveau du prétraitement de l’image, du choix des paramètres initiaux et au niveau du calcul des centroïdes.

Pour la suite de notre étude, ces articles sont résumés selon les points suivants : le mode de fonctionnement des optimisations dans le processus de FCM, les avantages et inconvénients de chaque optimisation ainsi que les technologies utilisées pour les expérimentations (les bases de données, le langage de programmation, ...).

4.6 Conclusion

Au cours de ce chapitre, nous avons pris connaissance des différentes étapes qui nous ont conduites au filtrage de nos articles. Nous avons également défini les niveaux d’optimisation de la méthode FCM. Dans la suite du document, nous énumérerons plus en détail les différentes optimisations répertoriées.

Chapitre 5

FCM et ses optimisations

5.1 Introduction

Face aux limitations de l'algorithme FCM, plusieurs optimisations diverses ont pu être expérimentées et approuvées. C'est ainsi que notre étude fait cas de ces dernières. Cette partie est organisée selon les trois niveaux d'optimisation que nous avons définis qui sont en premier point le prétraitement des images médicales ayant pour but d'augmenter considérablement la qualité de l'image à segmenter, en second point, le choix des paramètres initiaux recherchant principalement les meilleures méthodes pour pallier le choix aléatoire des paramètres de départ de la segmentation et en dernier point la mise à jour des centroïdes subdivisée en deux sous-parties qui sont : le calcul des centroïdes et la modification de la fonction objective qui a pour but de trouver les meilleurs centres de grappe pour la segmentation de l'image.

5.2 Optimisations au niveau du prétraitement des images : Débruitage

Le bruit est une dégénérescence certaine des images médicales. Il modifie les valeurs des pixels des images médicales acquises de manière aléatoire. Ce dernier crée des interférences avec le processus de diagnostic en médecine clinique. Le bruit et les caractéristiques indésirables constituent un obstacle majeur à une reconnaissance efficace dans tout système de reconnaissance [31]. Ils réduisent également la résolution du contraste et rendent difficile l'identification des tumeurs

normales et anormales par le médecin. Selon les différentes imageries que nous connaissons, différents types de bruits peuvent être observés [32] :

- **Le bruit additif** : il s'agit du bruit qui s'additionne au signal pur de l'image.
- **Le bruit multiplicatif** : ce type de bruit, aussi appelé bruit impulsif ou poivre et sel, provoque l'apparition de valeurs isolées très différentes des valeurs des pixels voisins.
- **Le bruit de quantification** : il est causé par la résolution avec laquelle l'illuminance est échantillonnée en chaque pixel.
- **Le bruit d'échantillonnage** : ce type de bruit est causé par la résolution spatiale avec laquelle le champ de vision observé par la caméra est échantillonné.

Pour plus d'efficacité dans la segmentation d'image, des techniques plus poussées sont élaborées pour la réduction du bruit. Certaines combinent des filtres déjà connus à des traitements supplémentaires et d'autres utilisent des méthodes toutes autres permettant à la segmentation d'être beaucoup plus fiable, rapide et facile.

5.2.1 Les filtres traditionnels

Le filtrage a pour but de réduire les effets du bruit sans trop affecter le signal. On distingue deux(2) groupes principaux de filtres à savoir :

- **Les filtres linéaires** qui possèdent les propriétés suivantes :
 - **L'invariance à la position** : Le résultat du filtrage ne dépend que du voisinage d'un pixel et non de la position absolue de ce dernier dans l'image.

- **Le respect des principes de mise à l'échelle et de superposition** : Le résultat du filtrage de la somme de deux images est le même que celui de la somme de deux images filtrées. Le principe est représenté comme suit 5.1 :

$$f(ax + bx) = af(x) + bf(y) \quad (5.1)$$

- **Les filtres non-linéaires** , dépendant du filtre utilisé, ce filtrage :
 - Permet de réduire le bruit impulsionnel (multiplicatif), ce que le filtre moyen (ou même gaussien) n'arrive pas à faire.
 - Préserve mieux les discontinuités (sans les adoucir).
 - Est généralement plus coûteux en temps de calcul que le filtre linéaire moyennneur.
 - Ne respecte pas les propriétés de commutativité et d'associativité du filtre linéaire.

À l'application de ces filtres, les images non bruitées (images lissées) sont renvoyées à l'entrée du processus de segmentation. Les résultats s'améliorent, mais ces paramètres fixes ne génèrent pas des résultats de débruitage optimaux, surtout dans le domaine médical. Il est donc important de proposer des algorithmes de débruitage adaptés aux images médicales qui estiment les distributions de bruit spécifiques aux pixels.

Au cours de notre étude, nous avons pu répertorier des filtres traditionnels appliqués sur des bases de données d'images médicales pour optimiser la segmentation de la méthode FCM.

1. Le filtre médian

Ce filtre a été utilisé par Patil R.S. et al. [33]. Dans la première étape de cette méthode, le prétraitement permet de supprimer

les artefacts et les composants inutiles en arrière-plan des images de mammographie. Il est également destiné à améliorer l'aspect de l'image pour éliminer les erreurs, le bruit ou pour mettre en évidence des caractéristiques spécifiques dans la mammographie.

La différence de bruit du filtrage médian est approximativement calculée pour une image avec un bruit de moyenne zéro sous une distribution normale qui est donnée par l'équation suivante(5.2) :

$$\mathbf{In}_{tm}^{im(pre)}(x, y) = \mathbf{median} \{ \mathbf{I}_{tm}^{im}(x - t, y - u) | t, u \in M \} \quad (5.2)$$

Ici, les images de mammographie d'entrée sont appelées \mathbf{I}_{tm}^{im} , M indique le nombre total d'images dans l'ensemble de données, M indique le masque 2D et l'image prétraitée est notée comme $\mathbf{In}_{tm}^{im(pre)}(x, y)$.

Dans le modèle développé par Murthy M.Y.B. et al. [34], on retrouve également ce filtre non linéaire et fonctionnant par substitution des pixels bruyants et voisins de l'image. En outre, il trie en fonction des niveaux de gris de l'image afin d'améliorer la qualité de l'image. Il comprend des effets supérieurs de réduction du bruit et améliore la qualité de l'image.

$$\mathbf{y}_{m,n} = \mathbf{median}[x_{(i,j)}], i, j \in C \quad (5.3)$$

Dans [33] et [34], le filtrage est effectué avant la segmentation. Il prend en entrée l'image initiale et fournit l'image filtrée pour le début de la segmentation.

Le filtre médian est choisi par les auteurs en raison de la simplicité de mise en œuvre, de sa robustesse, de sa capacité élevée de réduction du bruit de chatoiement (qui se manifeste comme une texture poivre et sel sur les images), de sa grande rapidité d'exécution et de l'amélioration de la résistance face au bruit

du modèle de segmentation proposé par rapport au FCM seul. Il améliore les bords et préserve les caractéristiques nettes des images d'entrée. Cependant, des inconvénients sont aussi observés comme l'inefficacité au-delà de 18% de bruit dans l'image et il peut aussi arriver que le lissage réduise ou supprime certaines zones importantes de l'image traitée.

Dans [35], il est utilisé par les auteurs Kumar D.M. et al. pour réduire le bruit dans un ensemble d'images de données cérébrales sans réduire la netteté de l'image. Chaque pixel est traité et remplacé par sa moyenne statistique la plus proche en fonction de la coordonnée de la fenêtre S représentant les coordonnées de la fenêtre de sous-image.

Il a été constaté par les auteurs que ce filtre protège les bords flous et les détails de l'image. Il protège également les détails aigus des hautes fréquences et augmente la résistance aux valeurs aberrantes.

2. Le filtre de Wiener

Dans l'étude présentée par Kumar D.M. et al. [35], la segmentation FCM proposée est rendue possible par l'amélioration de la capacité de réduction du bruit en appliquant un filtre de Wiener à la matrice de partition modifiée de la fonction objective de l'algorithme FCM avec des informations locales. La nouvelle matrice d'appartenance U' est donnée après l'application du filtre sur la matrice U (5.4) :

$$U' = \text{weiner}[U] \quad (5.4)$$

Margarat G. et al. [37] utilisent des ensembles de données de radiographie pulmonaire comme Shenzhen China (SC). Les images d'entrée sont redimensionnées à 512×512 pixels puis soumises au filtre qui élimine le bruit additif et supprime le flou en même temps. Il est optimal sur la base de l'erreur quadratique

moyenne (MSE) [38] qui se définit comme une mesure caractérisant la « précision » d'un estimateur (5.5).

$$WF(f_a, f_b) = \frac{G(f_a, f_b) T_{zz}(f_a, f_b)}{|(G(f_a, f_b))|^2 T_{zz}(f_a, f_b) + T_{mm}(f_a, f_b)} \quad (5.5)$$

Où :

- G est le filtre flou,
- T_{zz} est un spectre de puissance,
- T_{mm} est un bruit additif.

D'après les auteurs, ce filtre minimise l'erreur quadratique moyenne entre le processus aléatoire estimé (prétraitement de l'image) et le processus souhaité (segmentation). Il est une représentation linéaire d'une image primaire redimensionnée.

Le filtre a aussi permis aux auteurs d'obtenir une meilleure segmentation d'image 2D du FCM, une meilleure résistance face au bruit ainsi qu'un meilleur temps d'exécution. Ils ont également observé une meilleure classification par rapport au FCM seul avec une précision de 99.96% .

3. Le filtre non-local NLM

Le filtre NLM est utilisé dans l'article des auteurs Thilagam M. et al. [31]. L'expérimentation est menée sur une base de données d'images 2D. Il tire parti des redondances d'information présentes dans les voisinages non locaux des pixels de l'image. Il restaure chaque pixel de l'image bruyante en le remplaçant par la moyenne pondérée de l'intensité dans son voisinage non local.

Il est utilisé pour retirer le bruit rician qui est courant et apparaît naturellement dans les données d'imagerie par résonance magnétique (IRM) et qui est difficile à éliminer.

L'utilisation de cette méthode avant le début de la segmentation fournit aux auteurs une augmentation de la précision et

de la vitesse de segmentation par rapport au FCM classique. De plus, l'algorithme MLN est entièrement automatique, plus robuste et donne de meilleurs résultats de débruitage par rapport aux filtres gaussiens, médian, de Wiener, de diffusion et bilatéraux [39]. Cependant, aucun pseudo-code ou code de l'algorithme n'est présenté dans cet article.

4. Filtre de Bayes ou transformée en ondelettes basée sur le rétrécissement de Bayes

Dans la méthode proposée par Ali E. H. et al. [40], le filtre de Bayes rétrécit l'image bruyante originale avant d'y appliquer la transformée en ondelettes. C'est une méthode qui s'est avérée efficace pour le débruitage des images IRM. Un ensemble de données cérébrales IRM de 1296 cas de maladie d'Alzheimer a été utilisé dans cet article. Les étapes pour l'application de ce filtre sont :

- Étape 1 : Conversion des images IRM en niveaux de gris.
- Étape 2 : Conversion de l'image grise en flottant.
- Étape 3 : Appliquer le filtre de débruitage et régler la valeur du niveau à 3, choisir le mode de seuillage doux, et la valeur du seuil à 3 et l'ondelette sélectionnée est Boir6.8

Cependant, les auteurs ne font pas mention du taux d'amélioration observé grâce à l'application du filtre par rapport aux autres méthodes.

Le tableau suivant (5.1) résume les méthodes de réduction de bruit par application de filtre. La notation NC indique que les données ne sont pas fournies par les auteurs.

Le graphique (5.1) représente la comparaison de ces méthodes énoncées ci-dessus. Elle repose sur quatre métriques principales : le PSNR (Peak Signal-to-Noise Ratio), mesurant la qualité de reconstruction de l'image ; le SSIM (Structural Similarity Index), évaluant la similarité structurelle entre l'image originale et l'image filtrée ; le MSE (Mean Squared Error), indiquant l'erreur quadratique moyenne ; et le temps

Filtres	Expérimentations	Avantages	Inconvénients
Filtre médian	Phython 3.6, MIAS mammographie et kaggle	Capacité élevée de réduction du bruit, simplicité de mise en œuvre	Non efficace au delà de 18% de bruit dans l'image, réduction ou suppression de certaines zones importantes
Filtre de Weiner	Matlab 2017a et Python 3.6, IRM de Dataset-160 et Data-255, Shenzhen China (SC) et Montgomery Country (MC), CPU core I5 avec 4 GB RAM	Meilleur temps d'exécution et robustesse face au bruit	NC
Filtre non-local NLM	MATLAB R2017a, IRM et scanners de BrainWeb, OpenfMRI et IBSR, Intel(R) Core(TM) i3, 1.70 GHz CPU, 4 GB RAM, et Windows 10	Robustesse face au bruit	NC
Filtre de Bayes	Ensemble de données cérébrales IRM	Meilleure segmentation	Peu de détails sur l'expérimentation

TABLE 5.1 – Résumé des méthodes de réduction du bruit par utilisation des filtres

d'exécution, reflétant l'efficacité computationnelle de chaque méthode.

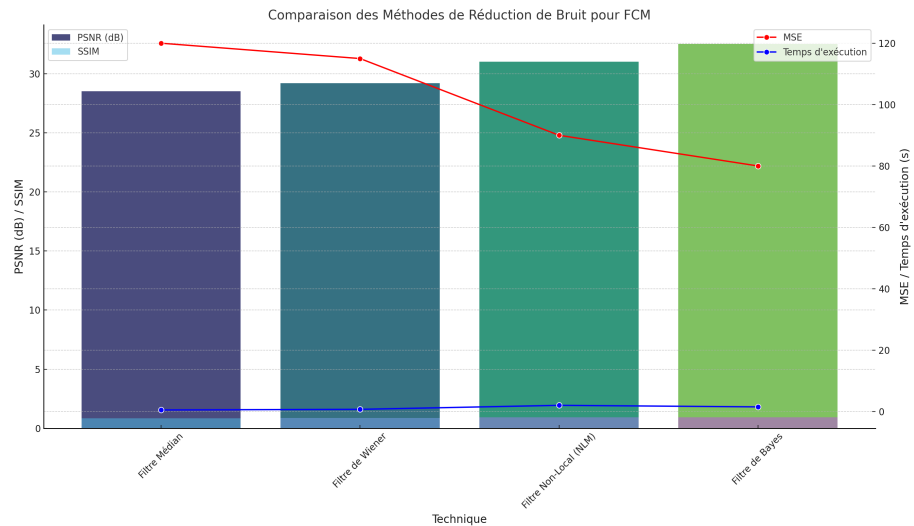


FIGURE 5.1 – Comparaison des méthodes de réduction de bruit pour FCM

5.2.2 L'égalisation des histogrammes

De nombreuses méthodes d'amélioration d'images sont utilisées aujourd'hui. L'une d'entre elles consiste à améliorer le contraste de l'image. Elle traite le domaine spatial des images en calculant l'histogramme pour augmenter leur contraste global (5.2).

L'idée de base est de cartographier les niveaux d'intensité du niveau de lumière par le biais d'une fonction de densité de probabilité (PDF). Ce traitement est réalisé pour ajuster les intensités de l'image afin d'améliorer le contraste.

1. BCDHE : Égalisation dynamique des histogrammes de contraste lumineux

Raj J.R.F. et al. [43] nous présentent la méthode BCDHE expérimentée sur la base de données d'images IRM. L'égalisation consiste à extraire des caractéristiques basées sur la texture, la forme, les statistiques et l'intensité. Cette étape permet de séparer le bruit de l'image afin de le supprimer sans altérer les informations utiles de l'image. BCDHE est une extension de l'égalisation d'histogramme qui fournit une image de sortie dont l'intensité moyenne est presque égale à celle des images d'entrée, conservant ainsi la luminosité des images d'entrée. Les sous-histogrammes sont générés pour chaque étape du processus d'histogramme, chacune d'entre elles étant contrôlée par l'équation :

$$f_i = Larg_i * \log_{10} N \quad (5.6)$$

Où :

- $Larg_i$ est la largeur de l'image,
- N le nombre total de pixels.

Elle a permis aux auteurs d'observer une meilleure segmentation d'images et par la suite une meilleure classification à 100% de spécificité et 98.6% de précision. Cependant, l'article ne fait aucune mention du code permettant d'appliquer l'égalisation au sein de l'algorithme FCM.

2. CLAHE : Égalisation d'histogramme adaptatif limité par contraste

Dans les études de Hu L. et al. [45] et Ali E.H. et al.[40],

l'égalisation a été utilisée sur un ensemble de données cérébrales IRM. CLAHE est une variante de l'égalisation adaptative de l'histogramme (AHE) qui vise à minimiser la suramplification du contraste. Elle fonctionne avec des tuiles qui sont de petites régions de l'image, au lieu de l'image entière et diffère de l'égalisation d'histogramme ordinaire en ce que la méthode adaptative calcule plusieurs histogrammes, chacun correspondant à une section distincte de l'image, et les utilise pour redistribuer les valeurs de luminosité de l'image. Les frontières artificielles sont supprimées en utilisant l'interpolation bilinéaire pour combiner les tuiles voisines.

Deux paramètres sont à retenir lors de l'utilisation de CLAHE, le seuil de limitation du contraste déterminé par le paramètre **ClipLimit** et **tileGridSize** qui détermine le nombre de tuiles dans la ligne et la colonne. Elle est utilisée lorsqu'une image est divisée en carreaux pour appliquer CLAHE.

L'algorithme se définit comme suit [46] :

Algorithm 3 Algorithme CLAHE

0: Input
 0: **Etape 1** : Définir la valeur initiale à 3,
 0: **Etape 2** : Définir la taille de la grille à 8x8.
 0: **Etape 3** : Application d'un filtre CLAHE sur une image sans bruit.
 0: Output : image égalisée. =0

Dans ces études, l'égalisation a servi à améliorer la qualité des images pour la segmentation. Les auteurs observent une amélioration du contraste local et de la définition des bords dans chaque région de l'image ainsi qu'une augmentation de la précision de segmentation par rapport au FCM seul.

Le tableau suivant (5.2) résume les méthodes de réduction de bruit par égalisation des histogrammes.

Égalisation	Expérimentations	Avantages	Inconvénients
BCDHE	MATLAB 2019b, IRM de BraTS 2020	Amélioration du contraste local, Réduction du bruit	Augmentation de la complexité et du temps d'exécution
CLAHE	MATLAB2017b, IRM de SIIM-ISIC et HAM10000, processeur Intel Core i7 64 bits avec 2,00 GHz et 8 Go de RAM	Amélioration du contraste local, réduction du bruit	Augmentation de la complexité

TABLE 5.2 – Résumé des méthodes de réduction du bruit avec l'égalisation des histogrammes

Au cours de notre étude, nous avons répertorié sept méthodes de réduction du bruit pour les images médicales. Ces méthodes peuvent être combinées entre elles pour améliorer le rendu final de l'image prétraîtée, nous avons par exemple parcouru des articles combinant le filtre médian et l'égalisation d'histogramme [31],[44]. Nous avons aussi constaté que la réduction du bruit est meilleure lorsqu'elle est choisie en fonction du type d'image et du type de bruit qu'elle renferme. De plus, les meilleures améliorations s'observent lorsque les études posent à la fois d'excellentes méthodes de réduction de bruit et des optimisations du FCM.

Ces différents articles nous ont permis de conclure que le débruitage est un point essentiel et primordial pour avoir de bonnes données de départ et que les images sans bruit sont efficacement segmentées à l'aide de la méthode FCM traditionnelle.

5.3 Optimisations du choix des paramètres initiaux

Dans la méthode FCM, le problème de la mauvaise initialisation entraîne la sensibilité du résultat final et impacte la performance de segmentation. En fait, le choix de différents centres de regroupement initiaux peut fortement affecter l'efficacité de la méthode [75]. Par conséquent, la sélection de meilleurs centres de clusters initiaux peut aider à surmonter ce problème. Il existe plusieurs méthodes pour ré-

soudre ou atténuer ce problème.

1. FCM modifié et arithmétique dynamique améliorée

Le travail de recherche proposé par Thiyagarajan S.K. et Murugan, K. [89] pour la segmentation des lésions d'AVC ischémique utilise une fonction accélérée (5.7) issue de l'algorithme d'optimisation arithmétique (MFCM-EEDAO) :

$$MAF = \left(\frac{M_{iter}}{C_{iter}} \right) * \alpha \quad (5.7)$$

Où :

- M_{iter} est le nombre maximum d'itérations,
- C_{iter} est l'itération en cours,
- α la constante.

La méthode d'optimisation nécessite un ajustement initial des valeurs minimales et maximales d'itérations. Ensuite, une population aléatoire de centroïdes de grappes candidats générés est prise comme données d'entrée de la méthode d'optimisation basée sur la population. Puis des solutions candidates sont générées pour le centre de la grappe à l'aide de la distribution de probabilité obtenue plus haut et des limites inférieure et supérieure du niveau de gris.

Enfin, les meilleurs centroïdes parmi cette famille de centroïdes de grappe X sont sélectionnés par la maximisation de la fonction d'aptitude d'Otsu (Otsu's Entropy function est une fonction d'aptitude pour les tâches de segmentation d'images qui recherche le seuil optimal par minimisation intra-classe (Kurita T 1992)). Et les résultats obtenus sont utilisés pour l'initialisation des centres de grappe pour la segmentation FCM.

Cette optimisation permet aux auteurs de calculer plus rapidement la fonction objective et d'obtenir une atténuation des effets du blocage à un optimum local, une plus grande robustesse face

au bruit ainsi qu'une meilleure segmentation de la région concernée avec une précision de 93% et un score DICE (mesure de la similarité entre deux ensembles de données) à 0.78 par rapport aux méthodes basées sur l'histogramme amélioré FCM qui a une précision de 80% et un score DICE de 0.59. Par contre, les auteurs observent aussi une limitation du nombre d'itérations due au temps d'exécution plus long.

2. FCM et algorithme génétique(FCM-GA)

L'algorithme présenté par Krasnov D. et al. [48] imite le processus de sélection naturelle pour déterminer la meilleure solution au problème. Il crée d'abord une population de solutions potentielles au problème aléatoirement et utilise ensuite les trois principes caractéristiques de l'AG pour combiner et optimiser ces solutions. L'algorithme suit les étapes suivantes (4) :

Algorithm 4 Algorithme génétique

```

0: Input
0: Générer aléatoirement une population P de n solutions
0: while ( $|P'| \neq n$ ) do
0:    $p' \leftarrow 0$ 
0:   while les critères d'arrêt sont remplis do
0:     Sélection de 2 solutions  $x$  et  $x_0$  de  $P$ 
0:     Croisement entre les deux parents  $x$  et  $x_0$  pour former deux enfants  $y$  et  $y_0$ 
0:     Mutation de  $y$  et  $y_0$  sous certaines conditions
0:     Ajout de  $y$  et  $y_0$  dans  $P_0$ 
0:   end while
0:    $P = P'$ 
0: end while
0: Output =0

```

L'application de cette optimisation permet aux auteurs d'obtenir d'excellents centres de grappes pour une segmentation claire et précise par rapport au FCM classique. Une plus grande résistance face au bruit et la diminution du temps de calcul sont également observées par les auteurs, avec une moyenne de temps par itération à 46.6s. Cependant, la complexité de calcul est plus grande que celle du FCM classique.

3. FCM et algorithme des lucioles (FCM-FA)

Cet algorithme basé sur le comportement des lucioles est expérimenté par Krasnov D. et al. [48]. Ces insectes se dirigent les uns vers les autres en fonction de la plus brillante et sont unisexes. Ce procédé permet la mise à jour constante et automatique des positions pour l'initialisation des points du FCM. L'algorithme est présenté comme suit (5) :

Algorithm 5 Pseudo-code Algorithme de lucioles

```

0: Générer la fonction objective  $f(x)$ 
0: L'intensité lumineuse  $I$  est donnée par  $f(x_i)$ 
0: Définir le coefficient d'absorption de la lumière  $\gamma$ 
0: while  $t < maxGeneration$  do
0:   for  $1 \leq i \leq n$  do
0:     for  $1 \leq j \leq n$  do
0:       if  $I_i < I_j$  then
0:         Déplacer la luciole  $i$  vers la luciole  $j$ 
0:       end if
0:       Varier l'attractivité en fonction de  $r$ 
0:       Évaluer la nouvelle solution et mettre à jour l'intensité lumineuse
0:     end for
0:   end for
0:   Classer les lucioles et trouver le meilleur  $\gamma$  mondial actuel
0: end while=0

```

Cette optimisation qui fournit de meilleurs centres de départ à FCM permet aux auteurs d'obtenir une segmentation plus claire et précise par rapport au FCM classique, une plus grande résistance face au bruit et la diminution du temps de calcul avec une moyenne de temps par itération de 3.4s. Cependant, la complexité de calcul est plus grande que celle du FCM classique.

4. FCM et algorithme biogéographique (FCM-BBO)

L'optimisation présentée par Krasnov D. et al. [48], est basée sur l'étude des modèles de distribution des espèces à travers les habitats. Pour une population N donnée, l'algorithme recherche

l'habitat avec le meilleur indice d'adéquation de l'habitat (IHH). Les coordonnées des meilleurs habitats selon les populations sont retenues pour servir à l'initialisation des centroïdes. Il est décrit par le pseudo-code suivant (6) :

Algorithm 6 Algorithme BBO

```

0: Générer aléatoirement une population  $P$  de  $n$  solutions
0: while le critère d'arrêt n'est pas rempli do
0:   Évaluer l'IHV(meilleur habitat) de chaque solution
0:   Calculer le nombre d'espèces  $S$ , le taux d'immigration  $l$  et le taux d'émigration  $m$ 
    pour chaque solution
0:   for  $1 \leq i \leq n$  do Utiliser  $\gamma_i$  pour décider, de manière probabiliste, de migrer vers la
    solution  $i$ 
0:     if  $rand(0,1) \leq \gamma$  then
0:       Remplacer une variable choisie au hasard dans la solution  $i$  par la variable de la
    solution  $j$ 
0:     end if
0:   end for
0: end while=0

```

Avec cette optimisation, les auteurs constatent une segmentation plus claire et précise par rapport au FCM classique, une plus grande résistance face au bruit et la diminution du temps de calcul moyen par itération de 1.1s. Cependant, la complexité de calcul est plus grande.

5. Regroupement flou amélioré sur la base d'un à priori de faible rang (FLICM)

Zhang X. et al. [49] proposent un schéma dans lequel les centres des grappes sont initialisés à l'aide de la détection des pics ou sommets de l'image. On y considère également la mesure de la parenté des pixels par la distance entre les tâches de l'image grâce à l'introduction d'un facteur flou pour remplacer l'effet des pixels voisins et éviter la charge de l'ajustement des paramètres.

Les centroïdes initiaux sont alors calculés grâce à l'équation suivante (5.8) :

$$v_i = \frac{(\sum_{j \in h_i} j * H_i)}{(\sum H_i)} \quad (5.8)$$

Où :

- $[i, h]$ est l'intervalle d'appartenance des pixels,
- u le degré d'appartenance,
- m le degré de flou.

L'ajout de ce paramètre permet de pallier les résultats pauvres pour les images fortement bruitées par l'utilisation de la distance euclidienne qui ne permet pas le traitement optimum des pixels éloignés pour améliorer la robustesse et à la diminution de l'efficacité de détection.

Les principaux avantages relevés par les auteurs sont l'évitement de l'enfermement dans les optimums locaux. Cependant, le temps d'exécution observé par les auteurs pour la méthode est de 53.017980s par rapport à FCM qui est à 2.279694s.

6. FCM et Optimiseur Chaotic Ant Lion (CALO)

Ahmed M.A. et al. dans [50] présente l'optimisation CALO. Elle est plus stable par l'utilisation d'une carte chaotique logistique, qui permet d'atteindre un bon équilibre entre l'exploration et l'exploitation. L'article ne partage pas de code, ni de pseudo-code ou de formule de l'optimisation.

Les auteurs observent un meilleur choix de clusters et de centroïdes avec l'optimisation CALO par rapport à FCM, Fast-FCM, FCM-PSO. Ce processus permet également de dépasser la limitation dans les valeurs initiales, une meilleure segmentation sur des images de tomodensitométrie du foie avec un indice de Jaccard à 0.62 et Dice de 0.76 ainsi qu'un meilleur temps d'exécution qui n'est pas précisé. Cependant, la stabilité des résultats n'est pas garantie sur tous les types de données.

7. MS-Interval Type-II FCM (MS-IT2FCM)

Garg H. et al. dans [51] exploitent l'algorithme Monkey Search (MS : processus de grimace des singes) pour le choix des clusters

pour FCM. La valeur idéale découverte par l'algorithme MS sert de base à une approche floue par intervalle qui est employée pour le regroupement. Il minimise la charge de calcul.

Le centre de cluster r pour l'algorithme IT2FCM est défini à l'aide de l'équation (5.9) qui explique les aspects novateurs de l'approche proposée.

$$r_i = r = \frac{\sum \mu(Z_i) Z_i}{\sum \mu(Z_i)} \quad (5.9)$$

Avec $\mu(Z_i)$ la moyenne des fonctions d'appartenance inférieures et supérieures des pixels obtenue grâce à l'algorithme MS.

La tâche décisive du regroupement est effectuée par IT2FCM. Cette méthode utilise deux fuzzifiers différents : $m1$ et $m2$, qui présentent des degrés flous distincts avec les limites inférieure et supérieure. Ces membres de l'IT2FCM ont été utilisés pour ajuster l'incertitude du fuzzifier « m » de FCM.

Grâce à ce procédé, les auteurs observent un temps d'exécution réduit à 0.4 ± 0.2 par rapport à FCM ($4s \pm 0.2$) et une segmentation précise avec une mesure de sensibilité à $98\% \pm 1.6$ et de spécificité à $98\% \pm 1.3$. En effet, la tumeur et la région des tissus sont clairement délimitées à l'aide de la technique proposée. Cependant, l'expérimentation n'a pas été effectuée sur un ensemble de données variées.

8. FCM et algorithme génétique à populations multiples (DMGA-FCM)

Les algorithmes génétiques traditionnels à populations multiples perdent la diversité des populations individuelles après de nombreuses itérations au sein de la population, et la capacité de recherche globale est réduite. Cette méthode de Ding W. et al. [52] propose l'ajout d'un opérateur de migration pour un choix optimisé des clusters (5.10).

$$L = C * N \quad (5.10)$$

Où L est la longueur de codage des individus génétiques, C est le nombre de centres de clusters, N est la dimension des caractéristiques.

Cet algorithme étend l'espace de recherche global, améliore la capacité d'adaptation de l'algorithme grâce à l'opérateur de contrôle flou probabiliste adaptatif permettant aux auteurs d'obtenir des centroïdes de regroupement mieux initialisés, ce qui réduit l'influence d'une mauvaise initialisation et permet un meilleur regroupement par rapport aux méthodes comme FCM(87.22%), FCM-PSO(90.22%) avec un indice de similitude de Jaccard à 93.20%. Mais les auteurs ont également relevé des inconvénients comme un plus long temps d'exécution d'environ 21.890s face à 12.653s pour le FCM, une diminution de la fiabilité pour les environnements de développement complexes.

9. FCM modifié et Auto-adaptation JAYA (MFCM-SAJAYA)

Natarajan S. et al. [47] expérimente le FCM modifié qui effectue la segmentation de l'image avec l'ajout d'une variable d'accommodation pour le calcul des clusters. Cette variable accommodative A_{fcm} est introduite afin d'obtenir un nombre adaptatif de grappes.

Par la suite, les données résultantes sont introduites dans l'algorithme SAJAYA permettant d'optimiser les variables de segmentation et de réduire le temps de calcul global et la complexité. Cet algorithme comprend les étapes suivantes (voir 7) :

Algorithm 7 Algorithme de SAJAYA

0: **Étape 1** : Taille initiale de la population X , condition de terminaison finale I_{max} , variables de conception d et nombre de sous-populations n sont initialisés.

0: **Étape 2** : Création des solutions candidates initiales et fixation du nombre d'itérations à $t = 1$.

0: **Étape 3** :

0: **if** $I_{(max)} \geq t$ **then** Augmenter le nombre $t = t + 1$

0: **end if**

0: **Étape 4** : diviser les valeurs en fonction des solutions, puis diviser la population en n sous-populations ($S1, S2, \dots, Sn$).

0: **Étape 5** : pour chaque sous-population, la solution est calculée.

0: **Étape 6** : En fonction de la valeur d'aptitude, modifier/rétentionner chaque sous population.

0: **Étape 7** : Toutes les solutions des sous-populations sont fusionnées.

0: **Étape 8** :

0: **if** la solution nouvellement créée (sous-population combinée) est supérieure à la solution précédente **then** remplacez-la à nouveau ;

0: **else**conserver la solution précédente.

0: **end if**

0: **Étape 9** : Dans ce cas, augmentez le nombre de sous-populations $n = n+1$ et le nombre d'itérations $t = t + 2$.

0: **Étape 10** : Continuer de l'étape 3 à l'étape 9.

0: Output =0

Les avantages relevés par les auteurs sont entre autres un meilleur processus de segmentation et une augmentation de la précision à 98% par rapport aux méthodes comme FCM-JAYA, FCM-ABC-JAYA qui affichent des pourcentages respectifs de 96%, 97%. Ils observent également un plus petit temps d'exécution de 2.18s face à 3.14s et 3.42s pour les méthodes FCM-JAYA et FCM-ABC-JAYA.

10. Algorithme de regroupement C-Ordered-Means flou (EnFCOM)

Dans l'étude de Moradi M. et Hamidzadeh J. [54], l'optimisation des C-moyennes floues ordonnées vise à réduire la dépendance à l'égard du paramètre de flou m en utilisant la théorie de l'entropie et un algorithme évolutif basé sur le chaos pour améliorer à la fois la sélection des centres de grappes et la mise à jour du degré d'appartenance.

Pour mieux gérer le caractère flou et éviter le niveau élevé d'incertitude et de flou, les auteurs combinent le principe de l'entropie maximale $\max E$ avec celui de l'incertitude.

EN-FCOM introduit un modèle d'optimisation qui se concentre sur deux objectifs contradictoires. Le premier objectif est de créer des grappes floues compactes et bien définies, tandis que le second objectif est de former des grappes qui se chevauchent afin d'identifier des groupes d'individus. Pour obtenir une grappe compacte et robuste au bruit, EN-FCOM minimise la fonction objective de FCOM (5.12).

$$J = \sum_{i=1}^c \sum_{k=1}^n \beta_{ik} (u_{ik})^m \mathcal{D}(x_k \cdot v_i); s.t. \sum_{i=1}^c u_{ik} = 1; \quad (5.11)$$

$$u_{ik} \in [0, 1];$$

$$\forall i = 1, \dots, c, \quad \forall k = 1, \dots, n$$

Où β_{ik} représente la typicité de la $k_{i\text{ème}}$ donnée par rapport à la $i\text{ème}$ grappe, u_{ik} indique le degré d'appartenance de la $k_{i\text{ème}}$ donnée par rapport à la $i\text{ème}$ grappe, D représente une mesure de dissimilarité entre la $k_{i\text{ème}}$ donnée et le $i\text{ème}$ centre de cluster.

Grâce à cette méthode, les auteurs ont observé une plus grande robustesse face au bruit, la résistance aux valeurs aberrantes de la segmentation FCM améliorée ainsi qu'une diminution de la dépendance vis-à-vis des paramètres initiaux par rapport aux méthodes comme FCM et FCOM. Cependant, le modèle proposé suppose que toutes les grappes ont le même degré de flou. Dans certains cas qui ne sont pas énumérés par les auteurs, cette hypothèse n'est pas respectée. Il est donc nécessaire que chaque grappe ait un degré de flou spécifique pour obtenir de meilleures performances.

11. K-means amélioré et FCM (IKCM-FCM)

Dans leur travail, Gomathi N. et Geetha A. [55] utilisent d'abord la méthode des K-moyennes améliorées (IKMC), qui permet d'éviter l'ajustement excessif. Le processus d'initialisation de l'algorithme IKMC est décrit dans les étapes suivantes (8) :

Algorithm 8 Algorithme IKCM

- 0: Input
 - 0: **Étape 1** : À partir de l'ensemble de données, un point d'échantillonnage est choisi au hasard comme premier centroïde de grappe initialisé.
 - 0: **Étape 2** : Les centroïdes des grappes restantes sont sélectionnés comme suit :
 - 0: Dans l'espace d'échantillonnage, la distance entre chaque échantillon est calculée et les centroïdes de la grappe sont initialisés, et la distance la plus courte entre eux est sélectionnée et représentée comme di .
 - 0: En utilisant la probabilité, les échantillons ayant la plus grande distance sont sélectionnés comme nouveau centroïde de la grappe.
 - 0: Le processus ci-dessus est répété jusqu'à ce que les centroïdes des k grappes soient calculés.
 - 0: L'algorithme K-means permet de calculer les centres de gravité finaux de k centres de gravité initiaux.
 - 0: Output =0
-

Ensuite, le regroupement est effectué à l'aide de l'algorithme FCM, ce qui améliore encore la capacité de classification d'après les auteurs. Dans cette étape, au moins deux centroïdes arbitraires parmi ceux obtenus plus haut sont sélectionnés et reçoivent des valeurs aléatoires. En utilisant l'expression suivante, la fonction d'appartenance est évaluée, où $m > 1$ et le numéro de la grappe est donné par cl :

$$ME_{ij} = \frac{1}{\sum_{\hat{k}=1}^{cl} \left[\frac{|x_i - cl'|}{|x_i - cl_j|} \right]^{\frac{2}{m-1}}} \quad (5.12)$$

Les auteurs observent une réduction de la sensibilité au bruit et une diminution de la complexité algorithmique et du nombre d'itérations par rapport au FCM.

12. Algorithme d'optimisation de la Veuve Noire et Contrôleur à logique floue (FCM-IBWO-FLC)

IBWO est présentée par Kishore D.V.S. et al. [56]. Elle permet de trouver des centroïdes optimaux en utilisant une méthode de calcul inspirée du cannibalisme des araignées veuves noires. L'utilisation d'un contrôleur logique flou (FLC) en conjonction avec l'IBWO fournit un moyen sophistiqué d'estimer les centroïdes optimaux dans le processus de regroupement FCM.

Le FLC incorpore la connaissance du domaine et les variables linguistiques, ce qui permet une détermination plus précise des centroïdes dans le processus de clustering, qui sont cruciaux pour une récupération précise des images (voir 9).

Algorithm 9 Algorithme d'optimisation Black Widow

```

0: Input
0: Étape 1 : Les individus de la population ont été initialisés au hasard à partir des
    limites de fonctionnement.
0: Étape 2 : Générer une population opposée :
0: for pour  $j = 1$  : taille de la population do
0:   for pour  $i = 1$  : nombre de variables de contrôle do

$$N_{(j,i)}^0 = x_i + y_i - N_{j,i}$$

0:   end for
0: end for
0: Étape 3 : trier la population actuelle et la population opposée, de la meilleure à la
    pire.
0: Étape 4 : Sélectionner  $n_p$  le nombre de solutions les plus adaptées de la population
    actuelle et de la population opposée en fonction de la taille de la population  $n_p$ .
0: Étape 5 : En utilisant la technique d'optimisation proposée, mettre à jour les variables
    de contrôle spécifiées.
0: Étape 6 : La population opposée a été générée à partir de la population actuelle en
    utilisant le taux de saut :
0: for  $j = 1$  : pop size do
0:   for  $i = 1$  : nombre de variables do
0:     if  $\text{tauxdesaut} > \text{rand}$  then  $\text{opop}(i,j) = \min(j) + \max(j) - \text{pop}(i,j)$ 
0:     else  $\text{opop}(i,j) = \text{popo}(i,j)$ 
0:     end if
0:   end for
0: end for
0: Étape 7 : Du meilleur au pire, trier la population (pop) et la population opposée
    (opop), puis choisir  $n_p$  le nombre de solutions les plus adaptées au sein de la population
    et de la population opposée.
0: Étape 8 : Arrêter l'itération si le critère de terminaison est satisfait ; sinon, passer à
    l'étape 5 pour la génération suivante.
0: Output =0

```

Les avantages observés par les auteurs sont l'amélioration de la formation de grappes de FCM, la réduction de la complexité en temps et en calcul, la robustesse de la méthode au bruit, aux valeurs aberrantes et à la variabilité couramment présente dans les images médicales.

13. C-moyennes floues générales (GFCM)

La méthode GFCM énoncée par Zhao K. et al. [57] permet de trouver le degré de flou idéal pour la segmentation de l'image

par la modification de la fonction objective.

La méthode GFCM permet aux auteurs d'obtenir un regroupement de meilleure qualité si le degré de flou est approprié et une meilleure segmentation d'image. Par contre, le degré de flou déterminé par GFCM face à différents ensembles de données peut ne pas être adapté. En plus, la complexité temporelle et computationnelle est identique à celle du FCM.

14. Regroupement spectral avec appartenance floue(FCSR)

Le clustering spectral utilise des représentations basées sur des graphes pour capturer les relations complexes entre les points de données. Intégrer la logique floue permet de calculer des degrés d'appartenance pour chaque cluster. L'algorithme de clustering spectral présenté par Zhou J. et al. [85] repose sur l'utilisation des valeurs propres et des vecteurs propres d'une matrice de similarité (matrice de Laplacien normalisé). La logique floue ajoute un calcul d'appartenance et la matrice de similarité est calculée comme suit (5.13) :

$$S_{ij} = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right) \quad (5.13)$$

Où σ contrôle l'étendue de la similarité.

Les auteurs ont répertorié des avantages tels qu'une meilleure gestion des frontières complexes entre clusters et une exploitation de la géométrie des données à travers une matrice de similarité non linéaire. Mais, ils ont également relevé une complexité computationnelle élevée et la sensibilité au bruit demeure.

15. Regroupement flou d'inspiration quantique(EQIE-FCM)

Inspiré par l'informatique quantique, cet algorithme présenté par Petaitiemthong N. et al. [86] utilise des principes comme la superposition et l'interférence pour explorer efficacement l'espace

des solutions. L'objectif de l'algorithme est de minimiser une fonction de coût quantique-flou (5.14) :

$$J = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m \|x_i - v_j\|^2 \quad (5.14)$$

Avec des ajustements basés sur des probabilités de superposition quantique :

$$u_{ij} = \frac{\psi_{ij}}{\sum_{k=1}^c \psi_{ik}} \quad (5.15)$$

Où ψ_{ij} est une fonction de probabilité quantique.

Les avantages observés par les auteurs sont une accélération de la convergence (avec une réduction du temps de convergence de 30%) grâce à la parallélisation et aux mécanismes inspirés des calculs quantiques, et une meilleure exploration de l'espace de solutions pour éviter les minima locaux. Cependant, on constate une implémentation plus complexe par rapport au FCM et une dépendance au modèle quantique.

16. Regroupement flou intégré profond(DEFEC)

Cette étude de Zhang R. et al. [87] combine la puissance des représentations hiérarchiques des réseaux neuronaux profonds et la flexibilité du regroupement flou. Les poids du réseau sont optimisés conjointement avec les centres de clusters, assurant une convergence simultanée des deux composants. L'objectif est de minimiser une fonction de perte combinée pour des données image complexes. Cette fonction est définie par (5.16) :

$$L = \alpha L_{\text{rec}} + \beta L_{\text{clustering}} + \gamma L_{\text{reg}} \quad (5.16)$$

Où L_{rec} est la perte de reconstruction utilisée pour s'assurer que l'espace latent conserve les caractéristiques essentielles des

données, L_{reg} le terme de régularisation pour éviter le surapprentissage et $L_{\text{clustering}}$ est la perte de regroupement flou définie par (5.17) :

$$L_{\text{clustering}} = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m \|z_i - v_j\|^2 \quad (5.17)$$

Avec z_i comme représentation latente de x_i .

La capacité à gérer des données complexes et de grande dimension comme les images et l'intégration naturelle de contraintes floues dans l'espace latent pour des regroupements plus précis (97% par rapport à 92% pour le FCM traditionnel) sont les avantages observés par les auteurs pour cette technique. Mais, l'entraînement d'un réseau neuronal profond est coûteux en termes de puissance de calcul et de mémoire, surtout lorsqu'il est combiné avec des techniques floues.

Le tableau suivant (5.4) résume les méthodes fournissant des choix de paramètres initiaux optimaux citées plus haut en y précisant les paramètres d'expérimentations, les bases de données utilisées par les auteurs, les avantages et inconvénients des optimisations. La notation NC indique que les données ne sont pas fournies par les auteurs et l'abréviation BD signifie bases de données.

Optimisation	Expérimentations	Avantages	Inconvénients
MFCM-EEDAO	Matlab 9.13 (R2022b), Tomographie et IRM de ISLES 2015, Notebook Horizon Edition 14 Intel(R) Core (TM)i7- 10510U CPU @ 2.30 GHZ avec 8 GB RAM	Calcul plus rapide de la fonction objective, Atténuation des effets du blocage à un optimum local, Robustesse face au bruit, Meilleure segmentation de la région concernée	Limitation du nombre d'itération due au temps d'exécution plus long
FCM-GA	Python3.8, Mammographie de VinDr-Mammo	Segmentation plus claire et précise, Plus grande résistance face au bruit, Disponibilité du code	Augmentation de la complexité de calcul
FCM-FA	Python3.8, Mammographie de VinDr-Mammo	Segmentation plus claire et précise, Plus grande résistance face au bruit, Disponibilité du code	Augmentation de la complexité de calcul
FCM-BBO	Python3.8, Mammographie de VinDr-Mammo	Segmentation plus claire et précise, Plus grande résistance face au bruit, Disponibilité du code	Augmentation de la complexité de calcul
FLICM	MATLAB R2016, Images médicales synthétiques, Intel processeur de 2.70 GHz avec 8 GB de RAM	Évite les enfermements dans les optimums locaux	Résultat pauvre pour les images bruitées et l'utilisation de la distance euclidienne rend les pixels éloignés moins bien traités, pour améliorer la robustesse, une grande fenêtre de recherche est utilisée, ce qui dégrade l'efficacité de la méthode, plus long temps d'exécution
FCM-CALO	MATLAB R2018b, scans abdominaux du foie, 64-bit, Windows 10, IntelCoreI7-8700 CPU	Meilleur choix de clusters et de centroïdes	NC

TABLE 5.3 – Résumé des méthodes d'optimisations au niveau du choix des paramètres initiaux(1)

Optimisation	Expérimentations	Avantages	Inconvénients
MS-IT2FCM	MATLAB, IRM et scanner de BRATS 2018	Segmentation précise et temps d'exécution réduit	NC
DMGA-FCM	Brain Web IRM	Améliore la capacité d'adaptation de l'algorithme	Plus long temps d'exécution
MFCM & SAJAYA	IRM de BraTS 2013	Meilleur processus de segmentation et augmentation de la précision, Diminution du temps d'exécution	NC
En-FCOM	MATLAB R2016, Mammographie de Breast cancer (Wisconsin) et images d'Iris, Intel processeur 2.70GHz, 8 GB de RAM.	robustesse face au bruit, résistance aux valeurs aberrantes, diminution de la dépendance vis-à-vis des paramètres initiaux	Même degré de flou pour toutes les grappes
IKM-FCM	MATLAB 2014a, type d'image IRM	Réduction de la sensibilité au bruit, de la complexité algorithmique et du nombre d'itérations	NC
FCM-IBWO-FLC	Matlab R2016b, 150 images IRM de kaggle	Améliore la formation de grappes de FCM et réduit la complexité de temps et de calcul	NC
GFCM	MATLAB, BD : tomodensitométrie de foie	Regroupement de meilleure qualité	Non adapté à différents types de données
FCSR	MATLAB R2014b, core i5-9500CPU avec 8G RAM, BD : Binary3, Coil20 et Coil1004, Leaves5 et Digit6	Meilleure gestion des structures complexes	Complexité computationnelle
EQIE-FCM	Images dentaires	Convergence accélérée	Expérimentation complexe
DEFC	BD : HHAR, STL-10, REUTERS	Précision de classification	Grandes exigences en données et en calcul

TABLE 5.4 – Résumé des méthodes d'optimisations au niveau du choix des paramètres initiaux(2)

Pour renforcer la clarté et la lisibilité des résultats présentés dans ce tableau, le graphique comparatif (5.2) a été intégré. Ce graphique, généré à l'aide de la bibliothèque de Python Matplotlib, offre une visualisation rapide et claire des performances des différentes optimisations de l'algorithme FCM. Il permet également de mieux identifier les forces et faiblesses relatives de chaque méthode sur plusieurs métriques clés, comme la précision et le temps de convergence.

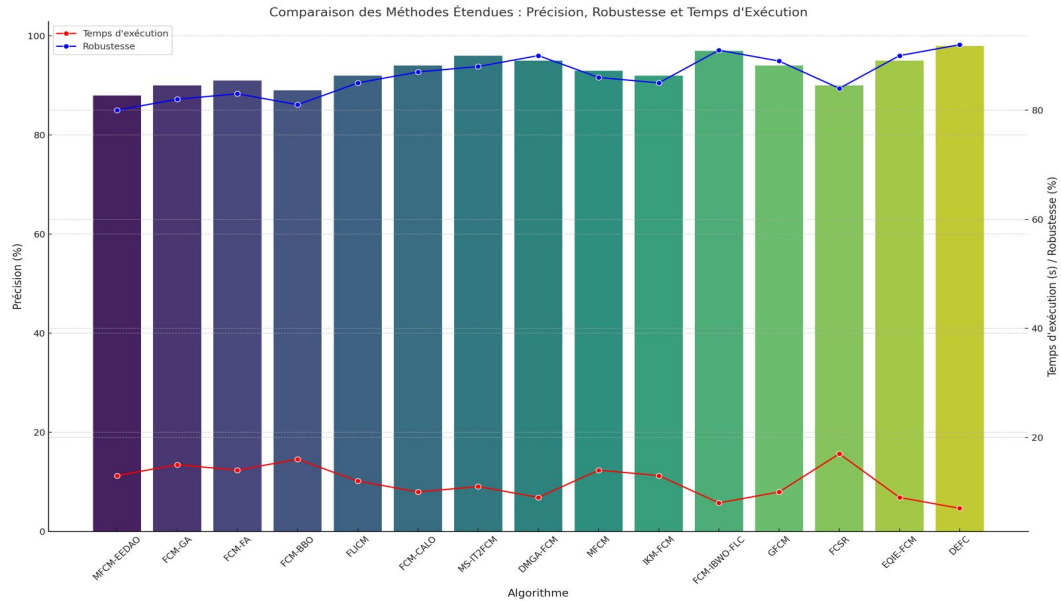


FIGURE 5.2 – Comparaison étendue des algorithmes d'optimisation des paramètres initiaux : Précision, robustesse et temps d'exécution

Au cours de l'étude de ces optimisations, nous avons constaté que le choix optimum des paramètres initiaux résout une grande partie des inconvénients liés à la méthode FCM (enfermement dans les optimums locaux, non-adaptation aux structures non-sphériques). Cependant, le débruitage reste une étape très importante. Mais l'inconvénient principal de ces optimisations, qui est souvent répertorié, est l'augmentation de la complexité algorithmique et du temps d'exécution (mesuré en secondes pour la méthode initiale et souvent en minutes pour les méthodes optimisées).

5.4 Optimisations de la mise à jour des centroïdes

Dans l'algorithme FCM appliqué à la segmentation d'images, un centroïde est défini comme le point central ou le prototype d'un cluster, représentant les caractéristiques moyennes des données qui lui sont associées. Plus précisément, le centroïde est calculé comme une moyenne pondérée de tous les pixels de l'image, où chaque pixel est pondéré par son degré d'appartenance flou au cluster considéré. La formule mathématique pour déterminer le centroïde v_j du cluster j est donnée par (5.18) :

$$v_j = \frac{\sum_{i=1}^N u_{ij}^m \times x_i}{\sum_{i=1}^N u_{ij}^m} \quad (5.18)$$

Où :

- x_i est le i -ème pixel de l'image,
- u_{ij} est le degré d'appartenance du pixel x_i au cluster j ,
- m est le paramètre de fuzzification qui contrôle le niveau de flou dans le processus de clustering,
- N est le nombre total de pixels.

Les centroïdes jouent un rôle crucial dans l'algorithme car ils déterminent la position et la structure des clusters dans l'espace des données. Ils sont continuellement mis à jour à chaque itération en fonction des degrés d'appartenance actuels, ce qui permet aux clusters de s'adapter progressivement pour mieux refléter la distribution réelle des données.

Dans le contexte de la segmentation d'images, les centroïdes capturent les caractéristiques essentielles des segments, telles que les intensités de couleur ou les textures, permettant une distinction plus précise entre les différentes régions de l'image. En outre, la précision de la segmentation dépend fortement de la précision avec laquelle les centroïdes représentent les clusters, ce qui souligne l'importance de leur calcul et de leur mise à jour rigoureuse tout au long du processus itératif de l'algorithme.

Au cours de notre étude, nous avons décelé deux sous-catégories d'optimisation des centroïdes, à savoir une au niveau de **la méthode de mise à jour des centroïdes** qui utilise un procédé de calcul différent et non lié à la fonction objective de FCM, et une autre qui **modifie la fonction objective** de FCM afin d'en tirer une formule de centroïdes optimisée et beaucoup plus efficace.

5.4.1 Mise à jour des centroïdes

1. Algorithme du loup gris et FCM (FCM-GWO)

Dans l'étude de Mohammadian-khoshnoud M. et al. [2], les paramètres initiaux sont choisis de façon aléatoire puis, après le calcul des premiers centroïdes, la méthode de calcul de GWO basée sur le mode de chasse des loups blancs est utilisée pour calculer de meilleurs centroïdes (avec pour paramètres initiaux les centroïdes de la méthode de base FCM) pour la segmentation.

GWO a une grande capacité d'exploration pour trouver la meilleure solution au problème (voir 10).

Algorithm 10 Algorithme GWO

```

0: Input
0: Initialisation de la position des loups  $X_i = (i = 1, 2, \dots, n)$ 
0: Initialisation  $\alpha, A, C$ 
0: Calcul de la valeur d'aptitude de chaque agent de recherche  $X_\alpha$  {Meilleur agent de
  recherche}  $X_\beta$  {Second meilleur agent de recherche}  $X_\delta$  {Troisième meilleur agent de
  recherche}
0: while  $t < maxiter$  do
0:   for Chaque agent de recherche do
0:     Mise à jour de la position des agents de recherche
0:   end for
0:   Mise à jour  $\alpha, A, C$ 
0:   Calcul de la valeur d'aptitude de chaque agent de recherche
0:   Mise à jour de  $X_\alpha, X_\beta, X_\delta$ 
0:    $t = t + 1$ 
0: end while
0: Output  $X_\alpha$  {La meilleure position} = 0

```

D'après les auteurs, cette optimisation empêche l'enfermement de FCM dans des optima locaux et permet d'obtenir une meilleure qualité de segmentation d'image.

2. Moyennes C hiérarchiques floues généralisées et algorithme du loup gris (GHFCM-GWO)

Dans cette étude d'Edwin D. P. et Sankara G. B. [44], le GHFCM utilise une fonction objective floue qui tient compte de

la fonction de distance hiérarchique et des contraintes spatiales. Ce travail choisit le point central optimal de la grappe à l'aide de l'algorithme GWO.

Les auteurs observent une plus grande précision de segmentation (98.6%), un meilleur temps d'exécution de 1.8s par rapport à 5.8s pour le FCM classique. Mais, cette méthode n'est pas adaptée aux données de grand volume.

3. FCM et Algorithme d'optimisation des baleines (WOA-FCM)

WOA est une nouvelle technique d'optimisation présentée par Tongbram S. et al. [6]. Elle est basée sur un essaim imitant le comportement des baleines à bosse lorsqu'elles chassent. Initialement, la position de la solution optimale étant inconnue, le WOA considère la proie cible comme la solution optimale ou proche de la solution optimale. Une fois que le meilleur agent de recherche est identifié, les autres agents de recherche changent de position par rapport au meilleur agent de recherche. Les équations mathématiques suivantes peuvent être utilisées pour décrire ce phénomène :

$$\begin{aligned} \vec{A} &= \left| \vec{C} \cdot \vec{Y}^*(t) - \vec{Y}(t) \right| \\ \vec{Y}(t+1) &= \vec{Y}^*(t) - \vec{D} \cdot \vec{A} \end{aligned} \quad (5.19)$$

$$\begin{aligned} \vec{A} &= \left| \vec{C} \cdot \overrightarrow{Y_{\text{rand}}} - \vec{Y} \right| \\ \vec{Y}(t+1) &= \overrightarrow{Y_{\text{rand}}} - \vec{D} \cdot \vec{A} \end{aligned} \quad (5.20)$$

$$\vec{Y}(t+1) = \vec{A}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{Y}^*(t) \quad (5.21)$$

Où t indique l'itération en cours, D et C sont les vecteurs de coefficients, Y^* et Y sont les vecteurs de position de la meilleure solution.

Les informations spatiales des pixels voisins sont utilisées pour identifier les pixels bruyants afin d'augmenter la robustesse face

au bruit. Par la suite, l'algorithme de la méthode FCM-WOA est le suivant(11) :

Algorithm 11 Algorithme FCM-WOA

```

0: Input
0: Les paramètres de WOA : taille de la population, nombre maximal d'itérations,  $d$ ,  $D$ 
  et  $C$  sont initialisés.
0: Initialisation des paramètres FCM.
0: Calcul de la fonction objective selon FCM
0: Affectation du meilleur agent de recherche.
0: while nombre d'itérations < nombre maximum d'itérations do
0:   Mettre à jour les paramètres  $d$ ,  $D$ ,  $C$ ,  $l$  et  $q$ 
0:   if  $q \leq 0.5$  and  $|D| \leq 1$  then
0:     Mis à jour de l'agent de recherche selon 1
0:   end if
0:   if  $q \leq 0.5$  and  $(|D| \geq 1)$  then
0:     Mis à jour de l'agent de recherche selon 2
0:   end if
0:   if  $q \geq 0.5$  then
0:     Mis à jour de l'agent de recherche selon 3
0:   end if
0:   La fonction fitness est calculée et s'il existe une meilleure solution, l'agent de recherche
    optimal actuel est modifié.
0:   Le processus de détection et de réduction du bruit est exécuté par remplacement les
    pixels bruyants par la moyenne des pixels voisins.
0: end while
0: Output les centroïdes et les valeurs d'appartenance
0: Segmentation de l'image. =0

```

Les auteurs observent une amélioration du coefficient de variation de partition $V_{pc}(0.96)$ et de l'entropie de la variance de partition $V_{pe}(0.07)$ avec FCMGWO qui est statistiquement plus importante que celle obtenue avec FCM (0.94 pour V_{pc} et 0.1 pour V_{pe}). Un meilleur évitement des optimums locaux, une vitesse de convergence supérieure à la méthode FCM initiale et une meilleure résistance au bruit sont également cités.

4. FCM et Optimisation par essais de particules (PSO-FCM)

Le principe PSO tel que présenté par Kottaimalai R. et al. [53] consiste à envoyer une population de particules dans l'espace, où

chaque particule vole à une certaine vitesse. À chaque étape, une vitesse individuelle est déterminée pour chaque particule en fonction de sa position dans l'espace. En fonction de la position actuelle de toutes les particules, l'essaim est guidé vers le meilleur emplacement (ce qui constituera les valeurs initiales). Ces valeurs sont calculées par la fonction de fitness suivante(5.22) :

$$fit_x = \frac{\sum_{i=0}^n H_i}{\sum_{i=0}^n \sigma_i^2} \quad (5.22)$$

Avec H la fonction d'entropie et σ_i^2 la variance de la i ème région.

Cette optimisation a fourni aux auteurs de meilleurs centroïdes, permettant ainsi une meilleure segmentation et classification des images segmentées par rapport au FCM.

Dans [58], la fonction objective FCM-PSO obtenue par les auteurs Hanuman V. et al. est définie par :

$$f_i = \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(y_j, z_i) \quad (5.23)$$

Avec z_i les centroïdes de grappes obtenus par la fonction fitness de PSO.

L'approche PSO présentée par Kottaimalai R. et al. [53] permet d'éliminer les limitations vis-à-vis des optimums locaux pour obtenir un meilleur taux de précision, une plus grande fiabilité sur des données réelles et un meilleur résultat de regroupement. Cependant, des inconvénients existent d'après les auteurs comme le coût de calcul plus élevé avec un temps de calcul de 22min pour une population de 200 individus, la convergence prématurée et la diminution de l'efficacité dans la recherche des meilleures positions.

Le tableau suivant (5.5) résume les méthodes permettant une mise à jour des centroïdes différentes citées plus haut en y précisant les

paramètres d'expérimentations, les bases de données utilisées par les auteurs, les avantages et inconvénients des optimisations. La notation NC indique que les données ne sont pas fournies par les auteurs et l'abréviation BD signifie bases de données.

Méthodes	Fonctionnements	Avantages	Inconvénients
FCM-GWO	Python 3.8, BD : SPSS 26	Plus d'enfermement dans les optimums locaux, une meilleure segmentation d'image, Disponibilité du code	NC
GHFCM-GWO	Matlab, ALL-AML : Images de leucemie, Processeur Intel i7 et 8 Go de RAM	Meilleure segmentation, temps d'exécution et résistance aux bruits et au blocage dans les optimums locaux	Pas adapté aux données de grand volume
FCM-WOA	MATLAB, IRM synthétiques et réelles corrompues par divers bruits	Evite le blocage dans les optimums locaux, une meilleure vitesse de convergence et une meilleure segmentation	NC
FCM-PSO	MATLAB 2016b, IRM du cerveau, Intel corei3-2310 M 2.10 GHz	Meilleure segmentation et classification des images segmentées	Coûts de calcul plus élevé et convergence prématurée

TABLE 5.5 – Résumé des méthodes utilisant la mise à jour des centroïdes

Pour renforcer la clarté et la lisibilité des résultats présentés dans ce tableau, le graphique comparatif (voir 5.3) a été intégré. Il est généré à l'aide de Python (Matplotlib) et offre une visualisation rapide et claire des performances des différentes optimisations de l'algorithme FCM. Il permet également de mieux identifier les forces et faiblesses relatives de chaque méthode sur plusieurs métriques clés, comme la précision et le temps de convergence.

5.4.2 Modification de la fonction objective

La fonction objective est centrale pour le FCM. Les méthodes qui seront présentées dans cette section introduisent de nouveaux paramètres qui ont pour but de rendre la segmentation plus précise et efficace.

1. FCM et noyau modifié avec entropie exponentielle (FCM-MK2E)

Afin d'obtenir une meilleure qualité des résultats de la segmen-

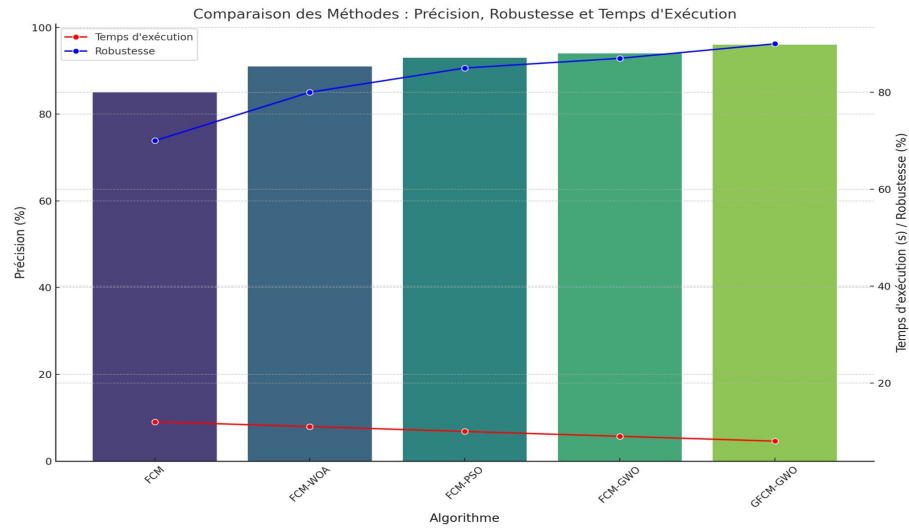


FIGURE 5.3 – Comparaison étendue des algorithmes améliorant la mise à jour des centroïdes : Précision, robustesse et temps d'exécution

tation, Ouchicha C. et al. [59] nous proposent un nouveau modèle partitionnel flou introduit en modifiant la fonction objective de l'approche des c-moyennes floues à noyau. Ce modèle introduit un terme qui implique l'influence des pixels voisins, une entropie exponentielle floue et un terme de pénalité logarithmique. Ces valeurs sont introduites dans la fonction objective pour le calcul des centroïdes.

L'idée de base de l'astuce du noyau est de résoudre les problèmes de séparabilité non linéaires des régions du tissu cérébral. Il s'agit d'appliquer une transformation ψ non linéaire pour projeter les pixels dans un espace de plus grande dimension, ce qui augmente les chances que les classes deviennent linéairement séparables dans l'espace de dimension plus grande projeté.

Cette optimisation permet, d'après les auteurs, la résistance aux valeurs aberrantes et au bruit, ainsi que de meilleurs résultats de segmentation (avec 98% de précision) par rapport aux méthodes comme KIFCM, KRFCMSC, KGFCM-S.

2. FCM basé sur les super-pixels (SPOFCM)

La méthode de clustering FCM est améliorée par Kumar S.N.

et al. [60] en intégrant les super-pixels similaires et les voisins spatiaux dans la fonction objective. On obtient la fonction objective modifiée du FCM basée sur les super-pixels :

$$J(U, V) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m D_{ij}^2 \quad (5.24)$$

La mesure de similarité utilisée dans la fonction objective basique est remplacée par la distance D incluant les super-pixels et le degré d'influence de ces derniers.

Cette optimisation augmente la robustesse de la segmentation face au bruit. De meilleures performances sont également obtenues en termes de mesures d'évaluation telles que la précision à 96.12%, la spécificité à 94.14%, la FAR(taux de fausses alarmes) à 18.72 face respectivement à 78.36%, 79.15% et 36.71 pour le FCM classique.

3. FCM et Distance de Mahalanobis (FCM-M)

La distance de Mahalanobis présentée par Krasnov D. et al. [48] est une mesure de dissimilarité calculée à l'aide d'une matrice de covariance qui prend en compte la variance et la corrélation des points de données. Cette méthode de calcul donne de nouvelles valeurs pour la matrice de covariance et introduit un facteur de régulation de la matrice de covariance défini par $\ln \Sigma_i^{-1}$.

Cette optimisation permet une approche multivariée et les avantages répertoriés par les auteurs sont une plus grande capacité d'évitement des enfermements dans les optimums locaux, une vitesse de convergence supérieure, une plus grande résistance au bruit, une meilleure détection des bords, un meilleur classement des détails de l'image et une réduction du nombre d'itérations dans l'algorithme numérique à une moyenne de 53% du FCM de base. Mais le temps de convergence estimé est de 2m20s par itération est plus long que celui du FCM.

4. FCM spatial (SFCM)

Un terme de régularisation spatial est utilisé par Ali N.A. et al. [62] et Dhirendra K. et al. [63] afin d'améliorer la méthode FCM. Pour chaque pixel voisin, la distance floue intuitionniste moyenne par rapport au centroïde d'un groupe particulier est utilisée pour diminuer l'effet du bruit. Ce terme permet de conserver les informations détaillées de l'image au cours du processus de segmentation, contrairement au lissage. Pour exploiter les informations spatiales, une fonction spatiale est définie comme suit (5.25) :

$$h_{ij} = \sum_{k \in NB(x_j)} u_{ik} \quad (5.25)$$

Où $NB(x_j)$ représente une fenêtre carrée centrée sur le pixel x_j et u_{ik} est la matrice d'appartenance des pixels.

La fonction spatiale est incorporée dans la nouvelle fonction objective. Ensuite, pour la mise à jour du vecteur des centroïdes, la fonction suivante est utilisée (5.26) :

$$V_i = \frac{\sum_{j=1}^N u'_{ij} x_j}{\sum_{j=1}^N u'_{ij}} \quad (5.26)$$

N représente le nombre de pixel et x_j un pixel à la position j et u'_{ij} est le degré d'appartenance du pixel x_j à la grappe C_i .

Les avantages de cette optimisation sont d'après les auteurs la diminution du temps d'exécution et l'augmentation de la robustesse face au bruit avec un indice VpeVpe(indice de meilleur partitionnement) à 0.0354 pour la méthode proposée et 0.2926 pour le FCM.

Le FCM spatial et non supervisé (SpFCM3D) est présenté et adapté par Kamarujjaman M. [64] pour la segmentation des images médicales 3D. Il consiste à introduire le poids des pixels en plus de l'information spatiale de chaque pixel dans la fonction objective. La méthode FCM spatiale est convertie pour segmenter l'image IRM 3D en utilisant le masquage 3D au lieu du masquage 2D. La fonction d'appartenance locale est définie et

combinée à l'appartenance globale pour supprimer l'inhomogénéité et le bruit au moment du regroupement dans l'espace 3D. La méthode proposée classe le volume de l'IRM cérébrale directement en trois régions homogènes dans l'espace 3D. La taille de l'image et l'information du voisinage conduisent le processus de segmentation. Le masquage dynamique a donc été utilisé pour mesurer la corrélation locale entre les images voisines.

$$J_{umsfcm} = \sum_{i=1}^C \sum_{j=1}^n \mu_{ij}^m d_{ij}^2 + \tau \sum_{i=1}^C \sum_{j=1}^n L_{ij}^m w_{ij}^2 \quad (5.27)$$

Où :

- W_{ij} est la fonction pondérée,
- L_{ij} est la fonction d'appartenance spatiale locale.

Le masquage 3D dynamique est conçu pour recueillir d'avantage d'informations et de caractéristiques du voisinage, qui sont utilisées pour évaluer la qualité de l'image, supprimer le bruit et optimiser la fonction objective. La fonction d'appartenance spatiale locale proposée conduit le processus de regroupement vers la supériorité par rapport à SpFCM3D et FCM3D (12).

Algorithm 12 Masquage dynamique 3D

```

0: INPUT
0: (  $nr \times nc \times nz$  ) {est la taille du volume de l'IRM}
0:  $CR = current_{row}, CC=current_{column}, CS=tranche_{courante}$ 
0: Pour chaque pixel du volume de l'image 3D, faire
0: if  $CR = 1$  then Le nombre de lignes du masque sera compris entre  $CR$  et  $CR + 1$ 
0: end if
0: if  $CR = nr$  then Le nombre de lignes du masque sera compris entre  $CR-1$  et  $CR$ 
0: else Le nombre de lignes du masque sera compris entre  $CR-1$  et  $CR + 1$ 
0: end if
0: if  $CC = 1$  then Le nombre de lignes du masque sera compris entre  $CC$  et  $CC + 1$ 
0:   if  $CC = nc$  then Le nombre de lignes du masque sera compris entre  $CC - 1$  et  $CC$ 
0:   else Le nombre de lignes du masque sera compris entre  $CC - 1$  et  $CC + 1$ 
0:   end if
0: if  $CS = 1$  then Le nombre de lignes du masque sera compris entre  $CS$  et  $CS + 1$ 
0: end if
0: if  $CS = nz$  then Le nombre de lignes du masque sera compris entre  $CS-1$  et  $CS$ 
0: else Le nombre de lignes du masque sera compris entre  $CS - 1$  et  $CS + 1$ 
0: end if
0: OUTPUT

```

Les avantages observés par les auteurs sont une meilleure résistance aux bruits, une bonne adaptation aux données médicales 3D, de meilleurs résultats aux indices V_{pc} (utilisé pour évaluer le caractère flou du système) et V_{pe} (indice de meilleur partitionnement) avec des valeurs respectives de 0.9772 et 0.0377 par rapport au FCM et un nombre minimum d'itérations. Cependant, aucun code ou de pseudo-code n'est présenté par les auteurs dans l'article de référence.

5. FCM et le voisinage maître-esclave

L'optimisation proposée par Wu C. et Wu W. [65] considère que le voisinage maître constitue les informations sur le voisinage local du pixel actuel, et le voisinage esclave en formation est le voisinage non local afin d'améliorer les performances de segmentation et la robustesse anti-bruit de l'algorithme sous l'action conjointe des informations de voisinage locales et non locales. Le modèle de voisinage maître-esclave est défini et introduit dans la fonction objective du regroupement flou pour la segmentation d'images. Une nouvelle fonction objective de l'algorithme

de segmentation robuste liée au regroupement flou est présentée comme suit (5.28) :

$$J(U, V) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \left[\|x_j - v_i\|^2 + G_{ij} + \sum_{r \in N_j, r \neq j} \frac{(1 - u_{ir})^m}{1 + d_{rj}} G_{ir} \right] \quad (5.28)$$

Avec G_{ij} le voisinage locale et G_{ir} le voisinage non-local.

D'après les auteurs, cette méthode augmente la robustesse face au bruit et aux valeurs aberrantes, en plus de l'augmentation de la fiabilité de la segmentation. Par contre, on observe un temps d'exécution beaucoup plus grand de 130s face à 5s, 10s et 20s pour les méthodes FCM, SFCM et FLICM.

6. Poids d'inertie et optimisation par essaim particulière (IWPSO-MFCM)

L'IWPSO est présenté par Palani D. et al. [66] pour améliorer la méthode FCM. Cette optimisation procède à la mise à jour de la fonction objective par l'introduction de deux fonctions spatiales. Ensuite, le FCM modifié avec des caractéristiques spatiales est appliqué afin d'obtenir la fonction objective suivante :

Les auteurs constatent une amélioration des performances de convergence (par rapport au PSO, au CPSO : Optimisation par essaimage chaotique et à l'IWPSO : Optimisation par essaim particulière à poids inertiel). Ils ont également observé une meilleure capacité de segmentation et une diminution considérable du taux de faux positifs (0.00 face aux méthodes comme CPSO et WPSO avec des taux respectifs de 3.72 et 3.44).

7. Algorithme de regroupement (ARKFCM-PSO)

La méthode utilisée par Ibtissem C. et al. [67] propose l'introduction d'un terme de régularisation pour la prise en compte des informations spatiales pour une meilleure fiabilité et du noyau de la fonction de base gaussienne pour une meilleure segmentation.

Après ce processus, la fonction objective ARKFCM avec PSO est minimisée pour le calcul des centroïdes.

La fonction de base gaussienne est définie par :

$$K(x_i, c_j) = \exp\left(-\frac{\|x_i - c_j\|^2}{\sigma^2}\right) \quad (5.29)$$

Les avantages observés par les auteurs sont une meilleure résistance aux bruits, une meilleure segmentation sur les images non sphériques. Elle s'est avérée également plus fiable que FCM, FCMPSO, ARKFCM d'après les indices Dice, Jaccard, Vpe(indice de meilleur partitionnement) et Vpc(coefficient de variation de partition) qui sont des indices de fiabilité pour les segmentations.

8. Minimum FCM – Artificial Bee Colony (MFCM-ABC)

Dans l'optimisation présentée par Kottaimalai R. et al. [53], une nouvelle fonction objective minimale est calculée avec la méthode de chasse des abeilles en colonies. On peut ainsi obtenir des centroïdes optimaux pour la segmentation. En incorporant le processus de mise à jour de la valeur de la fonction de poids dans le FCM conventionnel pour une convergence plus rapide et éviter le chevauchement de grappes. La fonction de poids est représentée par (5.30) :

$$W_{ij} = \frac{\sum_{x_n \in N_{i1+\alpha}^j} (d_{ij})^2}{\sum_{x_n \in N_i} \frac{1}{1+\alpha(d_{ij})^2}} \quad (5.30)$$

Où

- $\alpha = 45$, une valeur constante positive,
- N_i est le groupe des k pixels les plus proches du i^{th} pixel,
- D_{ij} la distance euclidienne,
- N_i^j le sous-ensemble de N_i appartient au cluster j .

Les auteurs ont pu observer les avantages comme la génération des régions plus homogènes que le FCM traditionnel, la gestion

des régions bruyantes, un temps de calcul plus court de 19.26s et une meilleure robustesse face aux bruits, ce qui conduit aussi à une meilleure segmentation.

9. Modified Interval Type-2 FCM(MIT2FCM)

Cette méthode d'AlZu'bi S., et al. [69] utilise l'appartenance spatiale des pixels. Chaque point de l'image a deux appartenances (supérieure et inférieure) qui sont calculées puis introduites à la fonction objective. On obtient :

$$J_m = \sum_{K=1}^C \sum_{l=1}^N \left(\frac{x_i}{\mu_{ik}} + \frac{x_i}{\mu_{ik}} \right) \quad (5.31)$$

Les auteurs ont observé une meilleure efficacité sur la segmentation des images 3D. Cependant, il y a une augmentation de la complexité algorithmique, du temps de calcul (matrice 3D au lieu de 2D) et dans cet article pas assez de détails sur l'optimisation MIT2 (son emplacement dans FCM,...).

10. FCM et restriction du retour sur investissement basée sur les repères anatomiques (FCM-ALD)

Cette procédure a été mise au point par Wantanajittikul K. et al. [70] parce que, dans certains cas, les valeurs LIC (concentration du fer dans le foie) dans la région du foie étaient dans un signal similaire à celles des organes adjacents. Étant donné que les résultats de la segmentation pourraient inclure une région non désirée, le retour sur investissement pour le processus de segmentation doit être restreint en utilisant des données de repères anatomiques. Grâce à cette optimisation, seuls les centroïdes de ces régions d'intérêts sont calculés et utilisés pour la segmentation.

Les auteurs ont pu constater la réduction des erreurs de segmentation et une meilleure efficacité par rapport au FCM clas-

sique. Mais, on peut toujours observer une sensibilité de la méthode face au bruit et l'article ne présente pas de détails sur l'élaboration de la méthode (équation, pseudo-code, code).

11. Hyper Tangente FCM (HTFCM)

La méthode d'optimisation HTFCM présentée par Bhimavara U. [71] regroupe les données en fonction de la distance hyperbolique entre les points de données et les centres de regroupement. Ensuite, elle attribue les valeurs d'appartenance aux points de données et ces points sont assignés aux grappes dont le degré d'appartenance est le plus élevé.

Cette optimisation permet aux auteurs de constater une meilleure résistance au bruit, une diminution du temps d'exécution, une augmentation de la fiabilité de la segmentation et une meilleure classification par rapport à plusieurs algorithmes récents FCM intuitionniste (IFCM), FCM possibiliste (PFCM), FCM intuitionniste possibiliste (IPFCM). Elle permet également de détecter et d'extraire les valeurs aberrantes dans la segmentation des images médicales. Le cadre proposé a donné d'excellents résultats très rapidement 8s par rapport à 22s pour FCM et efficacement avec un taux de précision de 98.89% par rapport à 95.75% pour FCM.

12. Optimal possibiliste flou C-moyennes et Algorithme de chasse des Corbeaux (PFCM-BCSO)

La méthode énoncée par Kumar D.M. et al. [35] combine l'algorithme PCM et BCSO (méthode de chasse des corbeaux) utilisée pour l'optimisation du calcul des centroïdes. Les solutions aléatoires initiales retenues sont les centres des grappes pour chaque groupe d'images cérébrales.

La fonction objective initiale du PFCM est donnée par :

$$J_m = \sum_{i=1}^n \sum_{j=1}^c (u_{ij}^*)^m \|y_i - a_j\|^2 \quad (5.32)$$

Où :

- $\|y_i - a_j\|$ est la distance euclidienne,
- c est le nombre de clusters,
- u_{ij} est le degré d'appartenance du point de données y_i au cluster j ,
- y est la valeur du pixel,
- a est le centre de cluster de l'ensemble de données Y ,
- m est un paramètre de pondération (généralement m1).

Puis le BCSO est introduit pour leur mise à jour, il s'agit d'un parcours de tous les points possibles (cachés et visibles) dans toutes les directions avant de choisir la position adéquate. La meilleure position est donnée grâce aux équations (5.33) :

$$\begin{aligned} A_{pj} &= \frac{f(\text{corbeau}_j)^l * S_{ap}}{f(\text{corbeau}_{moy}^l)} \\ E_{Bj}^l &= E_B^{max} - \frac{f(\text{meilleurcorbeau})^l}{f(\text{corbeau}_j)^l} \end{aligned} \quad (5.33)$$

Où

- $f(\text{corbeau}_j)$ est l'objectif d'efficacité du jème corbeau,
- f_{moy} est la moyenne de la meilleure et la pire position de corbeaux,
- S_{ap} est une quantité accidentelle désignée parmi A_{min} et A_{max} .

D'après les auteurs, ces optimisations permettent l'élimination de la sensibilité au bruit, un meilleur taux de précision de 99.9%, moins de faux positifs, de faux négatifs et une diminution du taux d'omission donnant les valeurs respectives : 0.001, 0.03 et 0.13 par apport aux méthodes comme FCM, IFCM, PFCM-PSO.

13. FCM intuitionnistes gaussiens à noyau basé sur la distance (DBKIFCM)

La méthode DBKIFCM présentée par Gosain A. et Dahiya S. [72] effectue le regroupement dans un espace de caractéristiques à haute dimension de manière à annuler la présence de valeurs aberrantes et d'obtenir des grappes plus précises et sans bruit. Cette modification s'observe dans la fonction objective pour éliminer les valeurs aberrantes dans le calcul des centroïdes.

Les auteurs observent une robustesse face au bruit et aux valeurs aberrantes, un meilleur calcul des centroïdes donc une meilleure segmentation par rapport au FCM, IFCM, KIFCM. Cependant, il y a aussi une augmentation de la complexité, une utilisation de données synthétiques et une absence des images testées dans l'article.

14. Regroupement FCM intuitionnistes basés sur le noyau à l'aide d'un algorithme immunitaire multiobjectif amélioré (KIFCM-IMOIA)

Wenke Z. et al. [73] dans leur article présentent la méthode KIFCM-IMOIA. Elle consiste à utiliser la méthode du noyau pour projeter les données dans un espace de dimension supérieure. Dans cet article, la fonction de base radiale gaussienne (GRBF) est utilisée pour améliorer la fonction objective de FCM. Cette fonction de base est définie par :

$$K(x, y) = \exp\left(\frac{-\|x - y\|^2}{\sigma}\right) \quad (5.34)$$

Où $\|x - y\|$ est la distance euclidienne et σ est le paramètre de largeur de bande.

Les auteurs observent une meilleure précision de regroupement, de meilleur indice Rand ajusté et mutuel normalisé par rapport aux méthodes FCM, KFCM, IFCM. Cependant, la complexité temporelle de KIFCM-IMOIA est plus grande que celle de FCM, KFCM et IFCM.

15. FCM et approche déformable du serpent (AFDF)

L'approche déformable du serpent est présentée par Murthy M.Y.B. et al. [74]. Les images prétraitées sont soumises au FCM et les résultats du regroupement sont ensuite transmis au modèle de déformation du serpent pour augmenter la précision de la segmentation. En outre, les centroïdes sont calculés puis mis à jour grâce à la technique ACV-DHOA. Le modèle de segmentation des tumeurs cérébrales proposé a pour objectif principal la minimisation de l'entropie et de la variance pour atteindre une performance de segmentation efficace, comme indiqué par l'équation (5.35) :

$$FF_1 = \arg \min_{\{cn_k, \alpha, \beta\}} \left(\text{var} + \frac{1}{Ent} \right) \quad (5.35)$$

Avec cn_k , α et β les paramètres de pondération.

La variance est définie par (5.36) :

$$\text{var} = \frac{\sum_{m=1}^{TM} (x_m - \mu)}{TM} \quad (5.36)$$

Où :

- μ la moyenne des pixel de l'image,
- TM le nombre total de pixel dans l'image,
- x_m la valeur du pixel m .

L'entropie est définie par (5.37) :

$$Ent = \sum_{m=0}^{TM-1} \rho r_m \log_2 \rho r_m \quad (5.37)$$

Où ρr_m représente l'histogramme normalisé ou la fonction de probabilité.

Cette approche a permis aux auteurs d'obtenir des résultats de segmentation améliorés pour les ensembles de données superpo-

sés avec une précision de 0.99253 par rapport au FCM classique avec une précision de 0.95163.

16. FCM et la méthode min-max

La méthode Minmax présentée par Yoosof M. et al. [75] propose la création d'une nouvelle fonction objective pour faire en sorte que toutes les grappes aient de faibles variances suivant les degrés d'appartenance. Ce processus permet d'éviter les grappes à forte variance afin d'obtenir des grappes qui ont des variances plus similaires. En d'autres termes, grâce à la nouvelle fonction objective, nous pouvons réduire l'influence d'une mauvaise initialisation sur le résultat final. De plus, une valeur p doit être spécifiée par l'utilisateur. Elle contrôle la sensibilité des poids entre les variances des grappes et doit être supérieure ou égale à 0 et inférieure à 1.

Grâce à cette optimisation, les auteurs ont obtenu une meilleure segmentation par rapport à FCM sur divers jeux de données (images d'iris, de mammographies, d'ecolis, de semences,...). Cependant, le temps d'exécution s'est vu croître, passant de 0.095 pour le FCM à 0.313 pour la méthode proposée.

17. C-moyennes floues adaptatives (AFCM)

Dans l'AFCM présenté par Simi M.G. et al. [76], l'échantillon et le taux de densité sont initialisés. Le paramètre γ est utilisé pour ajuster la grappe potentielle de centres. Dans ce cas, la densité de l'échantillon ρ_j est définie comme :

$$\gamma_j = X(D_{lp} - D_{bo}) \quad (5.38)$$

Où

- $X(y) = 1$ lorsque le taux de densité initialisé y_0 et 0 lorsque y_0 ,
- D_{lp} est la distance euclidienne de l'échantillon l_{th} et du ρ^{th} centre de la grappe,

— D_{bo} est une distance de rupture.

D'après les auteurs, cette méthode a permis une meilleure segmentation des images et la diminution des faux positifs et des faux négatifs dans la classification des images de radiographies avec une précision de 0.992 et 0.987 pour les deux jeux de données utilisés (Shenzhen China et Montgomery Country) par rapport au FCM.

18. FCM à apprentissage dynamique basées sur le PSO et influencées par le voisinage (DLPSO-NIFCM)

L'optimisation présentée par Chakraborty T. et al. [77], utilise une fonction objective convexe primaire tenant compte de la valeur d'appartenance d'un pixel ainsi que de l'appartenance de ses autres pixels voisins. Ensuite, une nouvelle transformation algébrique lui est appliquée pour concevoir une nouvelle fonction plus appropriée sans en perdre la convexité. Cette nouvelle fonction objective est compatible avec l'hybridation et n'importe quelle technique de recherche heuristique au sens propre. Enfin, un mécanisme d'isolation basé sur les graphes pour affiner les résultats de la segmentation est utilisé.

Les auteurs ont observé un meilleur taux de convergence, une réduction de la charge de calcul liée au PSO et une plus grande résistance face au bruit par rapport au FCM, FCM-PSO. Cependant, les taux n'y sont pas précisés.

19. Regroupement FCM amélioré (ImFCM)

La méthode de regroupement ImFCM utilisée par Ali E. H. et al. [40] préconise l'utilisation d'un filtre moyen pour calculer l'histogramme de l'image afin de calculer le centroïde des groupes. L'algorithme est décrit dans (13) :

Algorithm 13 Algorithmme ImFCM

- 0: Input
- 0: **Etape 1** : définir les valeurs initiales suivantes qui sont : - Nombre de bits. - Nombre de grappes. - Degré de flou. - Itération maximale. - Seuil Epsilon pour vérifier la convergence.
- 0: **Etape 2** la méthode du poids initial : Cette méthode initie une matrice à deux dimensions en fonction du nombre de grappes et du nombre de niveaux de gris pour calculer le poids.
- 0: **Etape 3** : Calculer la moyenne de l'image, en ajoutant la moyenne après l'avoir multipliée par la valeur α approximativement à 3 et en l'ajoutant à l'image principale, puis en divisant la valeur par $(1 + \alpha)$, cette méthode s'appelle l'image pondérée linéairement. $Moyenne = image + \alpha * filtre - moy / (1 + alpha)$
- 0: **Etape 4** Calculer le centroïde des grappes de la manière suivante : $X = \text{sum}(\text{histogram} * \text{number of gray levels}) * \text{power}(\text{weight} * \text{number of fuzziness})$. - $Y = \text{sum}(\text{histogram}) * \text{power}(\text{weight} * \text{number of fuzziness})$. - $Z = X/Y$.
- 0: **Etape 5** : méthode des poids - Set power = $-2 / \text{le nombre de flous}$. - $X = (\text{degre de gris} - \text{valeurs des centroïdes}) * \text{puissance}$. - $Y = \text{sum}(\text{niveau de gris} - \text{valeurs des centroïdes}) * \text{puissance}$. - $Z = X/Y$.
- 0: **Etape 6** : Vérifier si la valeur maximale absolue de (étape 5– Etape 2) est inférieure au seuil epsilon, puis arrêter, sinon passer à l'étape 4.
- 0: Output =0
-

D'après les auteurs, l'optimisation a permis une segmentation plus claire et précise par rapport au FCM.

20. FCM et supervision partielle basée sur des connaissances (KPSFCM)

Dans leur étude, Sriramakrishnan P. et al. [79] présentent KPSFCM. C'est une technique intermédiaire entre l'apprentissage supervisé et l'apprentissage non supervisé. Elle modifie la fonction objective par l'ajout d'un facteur d'échelle qui maintient un équilibre entre les motifs étiquetés et non étiquetés de l'image. Ce facteur permet de trouver le groupe de regroupement approprié pour le point de données en présence d'un champ de biais. La fonction objective obtenue est la suivante :

$$J_{ps} = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d_{ik}^2 + \delta \quad (5.39)$$

δ désigne un facteur d'échelle qui maintient un équilibre entre les motifs étiquetés et non étiquetés.

Les avantages d'après les auteurs sont une meilleure précision de segmentation, la robustesse face au bruit et au champ de biais par rapport au FCM et au K-means. On observe cependant une augmentation du temps de calcul passant de 33.03s pour FCM à 503.69s pour la méthode proposée.

21. FCM intuitionniste pondéré par l'information locale modifié & optimisation de l'aigle royal (MLWIFCM-GEO)

Les auteurs Dwivedi A. et al. [80] présentent dans leur article MLWIFCM-GEO. Cette méthode permet d'ajuster le degré d'influence K_{ij} des informations locales de regroupement en introduisant le poids de l'image locale. Dans les zones à fort bruit, les informations locales jouent un rôle essentiel dans l'algorithme de regroupement proposé. Ce degré est défini par (5.40) :

$$K_{ij} = \frac{\pi + \sigma_j^2}{\pi + \sigma^2} \quad (5.40)$$

Avec ρ_j^2 la variance des données de l'échantillon, ρ^2 l'erreur quadratique moyenne et π la petite constante.

Les auteurs observent grâce à cette méthode une diminution du temps d'exécution passant de 214.378ms pour l'approche Grabcut à 80.234ms pour l'approche proposée, une meilleure performance de segmentation et de classification par rapport au FCM classique. Par contre, il y a une absence de code et pseudo-code, une absence d'image de l'expérimentation et peu d'apport sur l'impact réel de l'optimisation GEO.

22. Algorithme de clustering de type II Intuitionistic FCM (T2IFCM)

L'optimisation T2IFCM est présentée par les auteurs Dahiya

S. et Gosain A. [81] pour une meilleure définition de la limite des grappes à travers l'introduction d'un degré d'hésitation π . Ce degré traite l'incertitude dans l'environnement flou, en particulier la région limite entre les grappes et permet d'en éviter le chevauchement. Les auteurs utilisent aussi des ensembles flous intuitionnistes (IFS) pour le calcul des grappes. Le degré d'hésitation est représenté par (5.41) :

$$\pi_{ij} = 1 - u_{ij} - (1 - u_{ij}^\alpha)^{\frac{1}{\alpha}}, \alpha > 0 \quad (5.41)$$

Où u_{ij} est le degré d'appartenance, $(1 - u_{ij}^\alpha)^{\frac{1}{\alpha}}$ est le degré de non-appartenance des pixels et α est un paramètre de réglage pour les algorithmes utilisant des ensembles flous intuitionnistes.

Les avantages observés par les auteurs sont une définition claire des grappes, la robustesse au bruit et aux valeurs aberrantes et l'amélioration de la position souhaitée des centroïdes par rapport aux méthodes comme FCM, IFCM, T2FCM et PSO-IT2FCM.

23. Algorithme hésitant parallèle FCM (PHFCM)

PHFCM présenté par Vela-Rincón V.V. et al. [82] introduit la possibilité de donner plusieurs valeurs possibles à un même pixel afin d'en choisir par la suite la meilleure. Pour ce faire, l'ajout de deux contraintes (u_0 et $u_{ij} = 1$) lors de la minimisation de la fonction objective de base de FCM.

Par la suite, l'ajout d'un terme λ pour l'utilisation de la technique du multiplicateur de Lagrange permet de trouver le minimum d'une fonction à plusieurs variables, à condition qu'il y ait une restriction sur les valeurs d'entrée.

Les différents avantages relevés par les auteurs sont la réduction du temps d'exécution et du nombre d'itérations, une

meilleure segmentation des images même colorées avec une précision de 98%. Aussi, la méthode est simplifiée et permet la segmentation en temps réel. Une autre contribution de ce document est l'utilisation de l'API OpenMP pour la programmation parallèle à mémoire partagée indépendante de la plate-forme en C, C++ et Fortran sur plusieurs plates-formes différentes. Elle permet une exécution en parallèle, ce qui réduit considérablement le temps de traitement en plus de converger en moins d'itérations par rapport à l'algorithme séquentiel. Par contre, la sensibilité face aux bruits reste présente.

24. FCM intuitionnistes probabilistes avec contrainte spatiale (PIFCM_S)

Dans la méthode présentée par Solanki R. et Kumar D. [83], on constate comme particularité l'ajout à la fois des poids p_{ij} , q_{ij} et ρ_{ij} correspondants aux valeurs d'adhésion, de non-adhésion et d'hésitation de chaque pixel respectivement, dans la fonction objective. Par la suite, l'inclusion d'un terme de régularisation spatiale α dans le problème d'optimisation de PIFCMS le rend robuste pour traiter le problème du bruit et de l'incertitude présents entre les limites des images dans le processus de segmentation.

Les avantages observés par les auteurs sont une plus grande robustesse face à différents niveaux de bruit par rapport à de multiples méthodes actuelles comme FCM, IFCM, FCM-S, FLICM, KFCM-S, ARKFCM, IIFCM, KIFCM, PIFCM, KWFLICM, NDFCM, WRFCM, FRFCM et DSFCMN.

25. Algorithme de co-clustering intuitif flou et PSO (IFCC)

Le principal défi de la segmentation des images cérébrales consiste à gérer l'incertitude qui découle des limites entre les différents tissus. Afin d'y remédier, l'IFCC est présentée par Verma, O.P. et Hooda, H. [84]. La généralisation des ensembles flous intuitionnistes (IFS) permet de générer des grappes distinctes qui

ne se chevauchent pas. Les paramètres de l'algorithme sont optimisés pour chaque image à l'aide de l'algorithme PSO??. Les nouveaux centroïdes obtenus sont calculés en tenant compte des variantes suivantes des IFS (5.42) :

$$P_{ik}^{IFS} = (\mu(P_{ik}), v(P_{ik}), \pi(P_{ik})) \quad (5.42)$$

Où les composants sont respectivement les degrés d'appartenance, de non-appartenance et d'hésitation de chaque pixel x_{jk} de la matrice pour k caractéristiques en termes de niveau d'intensité normalisé.

D'après les auteurs, cette méthode diminue le pourcentage d'erreur dans la segmentation d'image par rapport aux méthodes comme FCM et FCM intuitionniste. Elle augmente également la fiabilité de la segmentation automatique sans intervention d'un utilisateur. Mais le temps d'exécution est plus long passant de 1.60s pour FCM intuitionniste à 18.50s pour la méthode proposée.

26. FCM et regroupement possibiliste de c-moyennes (IPFCM)

La méthode présentée par Kollem S. et al. [46] propose la fusion des fonctions objectives du FCM et du PCM(regroupement possibiliste de c-moyennes) pour en obtenir une nouvelle afin de calculer les appartenances floues et possibles. Cette approche utilise ainsi les avantages des deux méthodes de regroupement.

Les auteurs observent une meilleure segmentation et classification avec une précision de 99.248%, ainsi qu'une plus grande résistance au bruit par rapport au FCM, au K-means et au PCM. Mais, il y a également une augmentation de la complexité de calcul de l'algorithme proposé.

27. FCM et le filtrage local sans biais basé sur les moments de Zernike (KBCFCM-LZM)

Présenté par Singh C. et al. [78], le filtre utilisé se base sur les

valeurs de similarité entre un pixel à l'emplacement actuel (i, k) et ses pixels voisins non locaux afin d'éliminer le bruit additif. La suite de la méthode consiste à déterminer les processus d'estimation du champ de biais et de segmentation simultanément sur l'image filtrée. Dans l'approche proposée, le champ de biais est estimé à l'aide de l'approche MICO (optimisation des composants intrinsèques multiplicatifs) et le processus de segmentation est formulé en utilisant l'image filtrée sans bruit Rician dans l'espace noyau. La nouvelle fonction objective est obtenue en considérant le biais ϕ , la fonction de noyau K et le multiplicateur de Lagrange λ (5.43) :

$$J_m = \sum_{i=1}^N \sum_{k=1}^C u_{ik}^m (1 - K(\phi)) + \sum_{i=1}^N \lambda_i \left(1 - \sum_{k=1}^C u_{ik} \right) \quad (5.43)$$

Où u_{ij} est le degré d'appartenance du pixel x_i au cluster j , N est le nombre de points de données, C est le nombre de clusters.

Ces étapes ont permis aux auteurs d'augmenter la capacité de traitement des structures complexes, la robustesse face aux différents degrés de bruit et de déformation dans les IRM de cerveaux avec 97.76% par rapport au KGFCM-S (FCM à noyau généralisé avec contrainte spatiale) 92.52%. Ils ont également constaté une convergence plus rapide sans précision des scores obtenus.

Notre étude des optimisations de la mise à jour des centroïdes nous a permis de constater que ces méthodes d'optimisation sont plus souvent utilisées et sont très souvent inspirées par le mode de vie des espèces animales vivant en groupe : essaim d'abeilles, bancs de poissons, meute de loups, groupe de baleines. Aussi, l'introduction d'un paramètre de régularisation pour contrôler l'information spatiale de l'image dans la fonction objective de FCM permet une grande évolution de la méthode vers une meilleure robustesse aux bruits et aux valeurs aberrantes, ainsi qu'à une meilleure adaptation aux formes non sphériques.

Les tableaux suivants (5.6) résument les méthodes qui présentent une modification de la fonction objective de la méthode FCM en y précisant les paramètres d'expérimentations fournis par les auteurs ainsi que les données utilisées pour les tests. La notation NC indique que les données ne sont pas fournies par les auteurs.

Méthodes	Fonctionnements	Avantages	Inconvénients
FCM-MK2E	Base de donnée : BrainWeb IRM, Ordinateur Intel Core i5, 2,5 GHz avec 8 Go de mémoire RAM	Meilleure résistante aux valeurs aberrantes et au bruit et meilleure segmentation	Augmentation de la complexité
SPOFCM	Matlab R2017a, Base de donnée : MIAS, Système Intel Core à 3,3 GHz et 8 Go de RAM	Meilleure résistance au bruit et meilleure segmentation	Augmentation de la complexité
FCM-M	Python 3.6, Image de mammographie	Meilleure gestion des incertitude et du bruit	Augmentation de la complexité de calcul
SFCM	Langage C, IRM de BrainWeb, Intel(R) Core(TM) i5- 3230M 4 cores 2.6 GHz CPU, Nvidia GeForce GT 740 m GPU	Meilleure résistance au bruit	Augmentation du temps d'exécution
SFCM3D	MATLAB (v. 2015a), ensemble de données d'images synthétiques, Windows 7 avec 4 Go de RAM et un processeur Intel(R) i3 cadencé à 3,10 GHz	Segmentation adaptée aux images 3D et efficace	Augmentation du temps d'exécution
Voisinage maître-esclave	Base de donnée : DIP3E, BSD300 et IRM de <i>Brain_Tumor_dataset</i>	Améliore la robustesse face au bruit et la qualité de la classification	Augmentation du temps d'exécution, Nombre non-optimal de grappes
IWPSO-MFCM	Matlab, Base de données : 40 différentes images d'entrée du fond de l'œil humain	Meilleure convergence et meilleure segmentation	Absence de l'algorithme de la méthode proposée
ARKFCM-PSO	Matlab 2020a, IRM de BrainWeb, ordinateur Intel Core i5 1,8GHz CPU, 8GRAM utilisant Microsoft Windows 10	Meilleure résistance aux bruits et meilleure segmentation sur les images non-sphériques, Plus fiable	NC
MFCM-ABC	Base de données Brats 2013	Régions plus homogènes que le FCM traditionnel, Meilleure gestion des régions bruyantes, temps de calcul plus court, Meilleure segmentation	NC
MIT2FCM	Matlab 2017, Base de données : CIRS 057, Garca d'image 3D CT scan, PC (Intel Core i7 4.30 GHz, 16 GB RAM)	Meilleure efficacité sur la segmentation des images 3D	Augmentation de la complexité algorithmique et du temps de calcul

TABLE 5.6 – Résumé des méthodes utilisant la modification de la fonction objective (1)

Pour résumer les résultats présentés dans ces tableaux, le graphe

Méthodes	Fonctionnements	Avantages	Inconvénients
FCM-ALD	IRM, PC Intel Corei7 4.30 GHz, 16 GB RAM	Diminution des erreurs de segmentation	sensibilité face au bruit
HTFCM	Scanners de LiTS, 3DIRCADb-1, CHAOS, Intel core i7@2.00 GHz, 8 GB RAM	Diminution du temps d'exécution, Augmentation de la fiabilité de la segmentation et de la résistance au bruit, Meilleure classification	Peu d'explication sur la méthode d'optimisation et absence de code
OPFCM-BCSO	Matlab version 2014a, IRM du cerveau de BRATS MICCAI	Pas de sensibilité au bruit et Meilleur taux de précision, Moins de faux positif, de faux négatif et diminution du taux d'omission	NC
DBKIFCM	MATLAB 2017a, intel i5 processor of 2.5 GHz and 8 GB RAM	Robustesse face au bruit et aux valeurs aberrantes et meilleur segmentation	Augmentation de la complexité, Utilisation de données synthétiques, Absence d'image
KIFCM-IMOIA	Base de donnée : image UCI	Meilleure précision de regroupement, Meilleur indice de fiabilité	Absence des images segmentées
AFDF	Matlab R2020a, Windows 10 64 bit OS 8G RAM, IRM de la BD Kaggle	Meilleur segmentation et classification des images	NC
Min-max FCM	Base de données : Breast Cancer Wisconsin, semences, iris	Expérimenté sur plusieurs données différentes	Sensible à la mauvaise initialisation des données de départ
AFCM	PYTHON 3.6, Radiographie du thorax de Shenzhen China, processeur Intel Core i5, 8 Go de RAM et une vitesse de 3,0 GHz	Meilleure segmentation	NC
DLPSO-NIFCM	MATLAB, tomodensitométrie (CT) de l'abdomen et scans des poumons, Intel i5 processor and 8 GB RAM	Meilleur taux de convergence, Réduction de la charge de calcul liée au PSO, Réduction de la sensibilité au bruit	NC

TABLE 5.7 – Résumé des méthodes utilisant la modification de la fonction objective (2)

comparatif suivant (5.4) a été intégré. Ce graphique, généré à l'aide de Python (Matplotlib), offre une visualisation rapide et claire des forces et faiblesses relatives de chaque méthode sur plusieurs métriques clés, comme la précision (en %), la robustesse (en %) et le temps d'exécution (en s).

5.5 Conclusion

Au cours de ce chapitre, nous avons parcouru de nombreuses optimisations de la méthode de segmentation FCM. Ces optimisations sont situées à plusieurs niveaux, comme celles au niveau du prétraitement

Méthodes	Fonctionnements	Avantages	Inconvénients
ImFCM	IRM du cerveau de 1296 cas d'Alzheimer	Meilleure segmentation	Peu d'images testées, Pas de détails sur les outils d'expérimentation
KPSFCM	Langage C, IRM de IBSR20, Windows8, 64 bit Intel i5-2500 3.4 GHz	Meilleure précision de segmentation	Augmentation du temps de calcul
MLWIFCM-GEO	MATLAB R2019b, Images de cellules humaines de BCCD et LISC, Processeur Core i5 8e génération 1,85 GHz de fréquence, 32G de RAM et GPU Intel UHD Graphics 620	Diminution du temps d'exécution, Meilleure performance de segmentation et de classification	Absence de code et pseudo-code et d'image d'expérimentation, Peu d'apport sur la méthode GEO et son impact
SpFCM3D	MATLAB 2015a, IRM de BrainWeb, environnement Windows 7 avec 4GB RAM et 3.10 GHz Intel(R) i3 processeur	Meilleure résistance aux bruits, Adaptation aux image 3D, Meilleur indice de segmentation, Diminution du nombre d'itération	Pas de code ni de pseudo code
T2IFCM	MATLAB-2017, Mammographie de MIAS, Intel Core i5 Processor-1600 MHz and 8GB RAM	Meilleure définition des grappes, Robustesse au bruit et aux valeurs aberrantes, Amélioration de la position souhaitée des centroïdes	NC
PHFCM	MATLAB-2017, Mammographie de MIAS, Core i5 Processeur-1600 MHz et 8GB RAM	Réduction du temps d'exécution et du nombre d'itération, Meilleure segmentation des images colorée, Segmentation en temps réel, Méthode simple	Pas d'optimisation pour résister aux bruits, Pas d'image médicale segmentée dans les résultats, Pas de code ou pseudo code
PIFCM _S	MATLAB 9.6, IRM de Simulated MRI brain volumes et Internet Brain Segmentation Repository (IBSR), 3.40GHz de fréquence et 16GB de RAM	Meilleure segmentation, Robustesse face au bruit	NC
IFCC	Matlab 7.9.0 (2009b), 20 images du Rajiv Gandhi Cancer Institute et Centre de recherche (RGCI&RC), Ordinateur avec 2.0 GHz CPU, 2GB RAM	Segmentation automatique et en temps réel, Méthode plus apte à gérer l'incertitude par rapport à la théorie des ensembles flous	Augmentation du temps d'exécution
IPFCM	MATLAB R2018a, IRM de BRATS2018	Meilleure segmentation et résistance au bruit	Pas de pseudo code, Augmentation de la complexité de calcul de l'algorithme optimisé
KBCFCM-LZM	MATLAB R2017a, IRM de BrainWeb et IBSR, Intel(R) Core(TM) i3, 1.70 GHz CPU, 4 GB RAM et Windows 10	Convergence plus rapide, Résistance au bruit et aux valeurs aberrantes	NC

TABLE 5.8 – Résumé des méthodes utilisant la modification de la fonction objective (3)

de l'image avec l'application de filtres (médian, wiener, non local,...) et l'égalisation d'histogramme (CLAHE, BCDHE) qui permettent pour




FIGURE 5.4 – Comparaison étendue des algorithmes pour les optimisations au niveau de la fonction objective

la plupart d'obtenir des images plus claires et plus nettes. Il existe également les optimisations au niveau du choix des paramètres initiaux, qui permettent de dépasser la limitation dans les optimums locaux. D'autres optimisations sont constatées au niveau de la mise à jour des centroïdes. Ces optimisations concernent de nombreuses méthodes de mise à jour et de calcul de nouveaux centroïdes afin de mieux détecter les régions d'intérêts des images médicales. Ces méthodes sont parfois utilisées ensemble ou isolées, mais toutes dans le même objectif : rendre la segmentation d'image médicale plus fiable, efficace.

Chapitre 6

Conclusion

Le clustering flou, et en particulier l'algorithme FCM, est un outil puissant pour la segmentation d'images médicales, offrant une flexibilité et une robustesse accrues par rapport aux méthodes de hard clustering. Bien qu'il présente des défis en termes de complexité computationnelle et de sélection de paramètres, ses avantages en termes de gestion des chevauchements et de segmentation précise en font une technique précieuse pour l'analyse d'images médicales. Dans notre mémoire, nous avons analysé les études sur les différents types d'algorithmes présentés dans la littérature dans le but d'améliorer la segmentation des images médicales par FCM. Notre méthodologie utilise quatre bibliothèques différentes grâce auxquelles nous avons analysé 50 méthodes d'optimisation de FCM issues de la littérature et localisées à trois niveaux différents pour la segmentation d'image. Nous avons regroupé les approches selon les types d'optimisation en N catégories situées au niveau du prétraitement des images à travers des débruitages, lissages et égalisations d'histogrammes, au niveau du choix des paramètres initiaux (degré de flou, clusters, centres de grappe) et au niveau de la mise à jour des centroïdes par la modification de la fonction objective ou la modification de la méthode de mise à jour des centroïdes.

Ce mémoire a exploré de manière systématique les différentes optimisations de l'algorithme Fuzzy C-Means (FCM) appliqué à la segmentation d'images médicales. En passant en revue les approches récentes et les avancées méthodologiques, nous avons mis en évidence les limites du FCM traditionnel et les stratégies adoptées pour améliorer

sa précision, sa robustesse et son efficacité computationnelle.

L'analyse des études recensées a permis d'identifier trois grandes catégories d'améliorations :

- Optimisation de la robustesse et de la précision via des variantes intégrant des métaheuristiques (FCM-PSO, FCM-GA), des modèles hybrides (FCM-Deep, FCM-Quantum) et des ajustements adaptatifs (T2IFCM, AFCM).
- Réduction du bruit et prétraitement des images en combinant FCM avec des filtres avancés tels que Médian, Wiener, NLM et Bayes, ainsi qu'avec des techniques d'égalisation d'histogramme comme CLAHE et BCDHE.
- Amélioration du temps de convergence par l'intégration de stratégies de calcul parallèle, d'algorithmes inspirés de la biologie computationnelle (FCM-IBWO-FLC, FCSR) et d'approches exploitant les architectures profondes (Deep Embedded FCM).

Les résultats des comparaisons expérimentales montrent que les approches intégrant des métaheuristiques ou des modèles hybrides offrent généralement un compromis optimal entre précision, robustesse et temps d'exécution, mais leur mise en œuvre peut être plus complexe. De même, l'intégration de techniques de prétraitement adaptées améliore significativement la segmentation, en réduisant les artefacts dus au bruit tout en conservant les détails importants.

Toutefois, malgré ces avancées, plusieurs défis demeurent. La majorité des approches optimisées nécessite des ressources computationnelles élevées, limitant leur applicabilité en temps réel. De plus, la généralisation des modèles reste un enjeu clé, notamment pour des bases de données d'images médicales variées et hétérogènes.

En réponse à ces défis, plusieurs pistes de recherche émergent :

- L'intégration de l'apprentissage profond avec FCM pour une segmentation plus adaptative.
- L'optimisation des architectures computationnelles (ex : calcul

sur GPU/TPU) pour réduire le temps de traitement.

- L'amélioration des techniques de réduction de bruit en combinant des méthodes existantes avec des stratégies de filtrage basées sur des modèles probabilistes ou flous avancés.

Cette revue systématique met ainsi en lumière les tendances actuelles et les perspectives d'évolution des algorithmes de segmentation basés sur Fuzzy C-Means, tout en soulignant la nécessité de nouvelles approches hybrides pour concilier efficacité, précision et rapidité dans le domaine de l'imagerie médicale.

Bibliographie

- [1] BrightCape Consulting. (2024, juin 17). Le Clustering : Définition et Top 5 Algorithmes. <https://brightcape.co/le-clustering-definition-et-implementations/>
- [2] Mohammadian-khoshnoud, M., Soltanian, A., Dehghan, A., et Farhadian, M. (2022). " Optimization of fuzzy c-means (fcm) clustering in cytology image segmentation using the gray wolf algorithm", BMC Molecular and Cell Biology, 23(02), DOI : 10.1186/s12860-022-00408-7.
- [3] CyberInstitut. (2024, juillet 17). Clustering : Techniques et applications. <https://cyberinstitut.fr/clustering-techniques-applications/>.
- [4] StudySmarter GmbH.(2024, juillet 17). Méthodes de clustering en génétique. <https://www.studysmarter.fr/resumes/biologie/information-genetique/methodes-de-clustering-en-genetique/>
- [5] DataScience. (2024, mai 10). Les algorithmes de clustering et leur importance dans l'apprentissage machine. <https://datascience.eu/fr/apprentissage-automatique/>
- [6] Simon T., Benjamin A. S., Loitongbam S.S., et Nameirakpam D. (2021). "A novel image segmentation approach using fcm and whale optimization algorithm". J Ambient Intell Human Comput. <https://doi.org/10.1007/s12652-020-02762-w>.
- [7] Datanovia. (2025, février 10). Fuzzy C-Means Clustering Algorithm. <https://www.datanovia.com/en/lessons/fuzzy-clustering-essentials/fuzzy-c-means-clustering-algorithm/>
- [8] Théorie des modèles. (2024, juillet 19).Wikipédia, l'encyclopédie libre. Page consultée le 12 :42, juillet 19, 2024 à par-

- tir de http://fr.wikipedia.org/w/index.php?title=Th%C3%A9orie_des_mod%C3%A8les&oldid=216930856.
- [9] Analyse des données. (2024, mars 4). Wikipédia, l'encyclopédie libre. http://fr.wikipedia.org/w/index.php?title=Analyse_des_donn%C3%A9es&oldid=213045141.
 - [10] Reconnaissance de formes. (2024, juillet 17). Wikipédia, l'encyclopédie libre. Page consultée le 15 :24, juillet 17, 2024 à partir de http://fr.wikipedia.org/w/index.php?title=Reconnaissance_de_formes&oldid=216881031.
 - [11] Proofpoint. (2025, 10 février). Qu'est-ce que la classification des données ou data classification ? <https://www.proofpoint.com/fr/threat-reference/data-classification>
 - [12] Segmentation d'image. (2024, mars 21). Wikipédia, l'encyclopédie libre. Page consultée le 08 :56, mars 21, 2024 à partir de http://fr.wikipedia.org/w/index.php?title=Segmentation_d%27image&oldid=213532153.
 - [13] Dzung L. P. et Jerry L. P. (2022). "An adaptive fuzzy c-means algorithm for image segmentation in the presence of intensity inhomogeneities". *Pattern Recognition Letters*, 20(1), 57-68. DOI : [https://doi.org/10.1016/S0167-8655\(98\)00121-4](https://doi.org/10.1016/S0167-8655(98)00121-4)
 - [14] Zhang, Y., Brady, M. et Smith, S. (2001). "Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm". *IEEE Transactions on Medical Imaging*, 20(1), 45-57.
 - [15] Szilágyi, L., Szilágyi, S. M., Benyó, B., et Benyó, Z. (2007). "A modified fuzzy c-means algorithm for MR brain image segmentation". *Engineering Applications of Artificial Intelligence*, 20(6), 743-750.
 - [16] Wikipedia contributors. (2024, July 2). Particle swarm optimization. Wikipédia, l'encyclopédie libre. Page consultée le 14 :13, October 28, 2024 à partir de https://en.wikipedia.org/w/index.php?title=Particle_swarm_optimization&oldid=1232289477
 - [17] Algorithme génétique. (2024, juillet 15). Wikipédia, l'encyclopédie libre. Page consultée le le 20 :35, juillet 15, 2024

- à partir de http://fr.wikipedia.org/w/index.php?title=Algorithme_g%C3%A9n%C3%A9tique&oldid=216832783.
- [18] Dihmani, H., Bouattane, O. et Grief, O. S.(2022). "A review on Suspicious-Regions Segmentation Methods in Breast Thermogram Image," 2022 2nd International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET), Meknes, Morocco, pp. 1-5, doi : 10.1109/IRASET52964.2022.9738265.
 - [19] Abdou M.A. (2022). Literature review : efficient deep neural networks techniques for medical image analysis. *Neural Comput & Applic* 34, 5791–5812. <https://doi.org/10.1007/s00521-022-06960-9>.
 - [20] Liu, X., Song, L., Liu, S. et Zhang Y. (2021). "A Review of Deep-Learning-Based Medical Image Segmentation Methods". *Sustainability*. 13(3) :1224. <https://doi.org/10.3390/su13031224>.
 - [21] Intelligence artificielle. (2024, octobre 23). Wikipédia, l'encyclopédie libre. Page consultée le 14 :16, octobre 23, 2024 à partir de http://fr.wikipedia.org/w/index.php?title=Intelligence_artificielle&oldid=219691066.
 - [22] Omar A., Wiem A., Anup S., Ersin E., Mohammad A. A. A. et Yogesh K. D. (2023). "A systematic literature review of artificial intelligence in the healthcare sector : Benefits, challenges, methodologies, and functionalities", *Journal of Innovation & Knowledge*, Volume 8, Issue 1, 100333, ISSN 2444-569X, <https://doi.org/10.1016/j.jik.2023.100333>.
 - [23] Ana Barragán-Montero, Umair Javaid, Gilmer Valdés, Dan Nguyen, Paul Desbordes, Benoit Macq, Siri Willems, Liesbeth Vandewinckele, Mats Holmström, Fredrik Löfman, Steven Michiels, Kevin Souris, Edmond Sterpin, et John A Lee. (2021). "Artificial intelligence and machine learning for medical imaging : a technology review " *Physica Medica : European Journal of Medical Physics*, 83 :242–256, 2024/10/28, ISBN : 1120-1797. DOI : 10.1016/j.ejmp.2021.04.016.
 - [24] Hanane, D., Omar, B. et Ouafae, S. G. (2022). "A review on Suspicious-Regions Segmentation Methods in Breast Ther-

-
- mogram Image," 2022 2nd International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET), Meknes, Morocco, pp. 1-5, doi : 10.1109/IRASET52964.2022.9738265.
- [25] Bhawna, D., Neetu, M. et Megha, M. (2020). "Medical Image Segmentation Techniques and Their Relevance in Contemporary Imaging," 2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), Noida, India, pp. 1306-1310, doi : 10.1109/ICRITO48877.2020.9197906.
 - [26] Pawan K. M., Pradeep K. S., Swapnita, S., Vipul, N., Marcin, P., Tatiana, J. et Maria G. (2023). "A comprehensive review of deep neural networks for medical image processing : Recent developments and future opportunities,Healthcare Analytics",Volume 4,100216,ISSN 2772-4425,https ://doi.org/10.1016/j.health.2023.100216.
 - [27] Chetna, K., Anshu, S. et Poonam, P. (2021). "A Brief Review on Clustering Based Medical Image Segmentation Algorithms with Issues and Challenges," 2021 9th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), Noida, India, pp. 1-8, doi : 10.1109/ICRITO51393.2021.9596154.
 - [28] Anfel, M., Ines, H., EL-Hachemi, G. et Mahiou R. (2020). "La segmentation des images médicales en utilisant les champs de Markov cachés et la technique Deep Learning". DOI :10.13140/RG.2.2.24745.21605.
 - [29] Ramesh, K., Kumar, GK., Swapna, K., Datta D. et Rajest SS.(2021)."A Review of Medical Image Segmentation Algorithms". EAI Endorsed Transactions on Pervasive Health and Technology. 7. 10.4108/eai.12-4-2021.169184.
 - [30] Bhawna, D., Neetu, M. et Megha, M. (2020). "Medical Image Segmentation Techniques and Their Relevance in Contemporary Imaging," 2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), Noida, India, pp. 1306-1310, doi : 10.1109/ICRITO48877.2020.9197906.

-
- [31] Thilagam, M., Arunesh, K. et Rajeshkanna, A. (2020). "Analysis of brain MRI images for Tumor segmentation using Fuzzy C means Algorithm," 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC), Coimbatore, India, pp. 183-186, doi : 10.1109/ICESC48915.2020.9155646.
 - [32] Patrick, H. et Denis, L. (Dernière révision : mai 2017). Page consultée le mars 21, 2024 à partir de <chrome-extension://efaidnbnmnibpcajpcglclefindmkaj/https://wcours.gel.ulaval.ca/2017/a/GIF4100/default/5notes/A2017TraitementImagesPartie1PageWeb.pdf>
 - [33] Rajeshwari, S., Patil, N.B. et Rashmi, P. (2022). "A new automated segmentation and classification of mammogram images". *Multimed Tools Appl* 81, 7783–7816. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-022-11932-1](https://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-022-11932-1)
 - [34] Murthy, MYB., Koteswararao, A. et Babum, MS. (2021). "Adaptive fuzzy deformable fusion and optimized CNN with ensemble classification for automated brain tumor diagnosis". *Biomed Eng Lett.* 2021 Nov 7 ;12(1) :37-58. doi : 10.1007/s13534-021-00209-5.
 - [35] Maruthi K. D., Satyanarayana, D. et Giri Prasad, M. N. (2021). "MRI brain tumor detection using optimal possibilistic fuzzy C-means clustering algorithm and adaptive k-nearest neighbor classifier". *J Ambient Intell Human Comput* 12, 2867–2880. [https ://doi.org/10.1007/s12652-020-02444-7](https://doi.org/10.1007/s12652-020-02444-7)
 - [36] Satyasis, M., Premananda, S. et Manas, Ranjan, S. (2019). "MASCA–PSO based LLRBFNN model and improved fast and robust FCM algorithm for detection and classification of brain tumor from MR image". *Evol. Intel.* 12, 647–663. [https ://doi.org/10.1007/s12065-019-00266-x](https://doi.org/10.1007/s12065-019-00266-x)
 - [37] Simi, Margarat, G., Hemalatha, G., Annapurna, M., Shaheen, H., Maheswari, K., Tamijeselman, S., Pavan, Kumar, U., Banupriya, V. et Alachew, Wubie, F. (2022). "Early Diagnosis of Tuberculosis Using Deep Learning Approach for IOT Based Healthcare Applications". *Computational Intelligence and Neuroscience.* 2022. 1-9. 10.1155/2022/3357508.
 - [38] Erreur quadratique moyenne. (2024, juin 3). Wikipédia, l'encyclopédie libre. Page consultée le 09 :28, juin 3, 2024 à par-

tir de http://fr.wikipedia.org/w/index.php?title=Erreur_quadratique_moyenne&oldid=215629812.

- [39] Catherine, F. et Sabine L. (2023). Extraction et gestion des connaissances : actes de la conférence egc'2023 ,C. Faron and S. Loudcher, BoD - Books on Demand, 2023, pages 247-257. <https://hal.science/hal-04169619>.
- [40] Esraa, Ali, H., Sawsan, S. et Zaid Makki F. (2023). "Novel Improved Fuzzy C-means Clustering for MR Image Brain Tissue Segmentation to Detect Alzheimer's Disease". International Conference on Computer and Applications (ICCA), Cairo, Egypt, 2023, pp. 1-6, doi : 10.1109/ICCA59364.2023.10401833.
- [41] Compression par ondelettes. (2024, avril 15). Wikipédia, l'encyclopédie libre. Page consultée le 13 :28, avril 15, 2024 à partir de http://fr.wikipedia.org/w/index.php?title=Compression_par_ondelettes&oldid=214277967.
- [42] OpenAI. (2025, février 10). ChatGPT-4 (modèle conversationnel d'intelligence artificielle, version 4.0). <https://openai.com/chatgpt>
- [43] Raj J.R.F., Vijayalakshmi K., Priya S.K. et Ahilan A. (2024). "Brain tumor segmentation based on kernel fuzzy c-means and penguin search optimization algorithm". SIViP 18, 1793–1802 . <https://doi.org/10.1007/s11760-023-02849-9>
- [44] Edwin, Dhas, P. et Sankara, Gomathi, B.(2020). A novel clustering algorithm by clubbing GHFCM and GWO for microarray gene data. J Supercomput 76, 5679–5693 . <https://doi.org/10.1007/s11227-019-02953-z>
- [45] Hu L., Zhang Y., Chen K. et Mobayen S.(2022). A computer-aided melanoma detection using deep learning and an improved African vulture optimization algorithm. International Journal of Imaging Systems & Technology. 32(6) :2002-2016. doi :10.1002/ima.22738
- [46] Kollem S., Reddy, K.R. et Rao D.S. (2021). An optimized SVM based possibilistic fuzzy c-means clustering algorithm for tumor segmentation. Multimed Tools Appl 80, 409–437 . <https://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-020-09675-y>,

-
- [47] S. Natarajan, V. Govindaraj, P. R. Murugan, Y. Zhang, A. P. Thiagarajan et Uma,K. (2023). "Tumour region detection in MR brain images using MFCM based segmentation and Self Accommodative JAYA based optimization," 2023 3rd International Conference on Advances in Computing, Communication, Embedded and Secure Systems (ACCESS), Kalady, Ernakulam, India, pp. 340-345, doi : 10.1109/ACCESS57397.2023.10201006.
 - [48] Krasnov D, Davis D, Malott K, Chen Y, Shi X. et Wong A. (2023). Fuzzy C-Means Clustering : A Review of Applications in Breast Cancer Detection. *Entropy*. 25(7) :1021. doi :10.3390/e25071021.
 - [49] Xiaofeng Zhang, Hua Wang, Yan Zhang, Xin Gao, Gang Wang et Caiming Zhang .(2021). Improved fuzzy clustering for image segmentation based on a low-rank prior. *Comp. Visual Media* 7, 513–528 . <https://doi-org.biblioproxy.uqtr.ca/10.1007/s41095-021-0239-3>
 - [50] Ahmed, M. A., Samir, A. E. et Ahmed, B. Z. (2022). "A robust Segmentation Model-based Fuzzy Swarm Intelligence and Logistic Chaotic Map for Hepatic CT Focal Lesion Segmentation," 2022 10th International Japan-Africa Conference on Electronics, Communications, and Computations (JAC-ECC), Alexandria, Egypt, pp. 264-269, doi : 10.1109/JAC-ECC56395.2022.10043913.
 - [51] Harish, G., Saravanan, A., Nagarajan, D. et Senthilkumar, A. (2024). Smart system for identifying the various pathologies in MR brain image using Monkey Search based Interval Type-II Fuzzy C-Means technique. *Multimed Tools Appl.* <https://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-024-18808-6>
 - [52] Weiping, D., Zhihao, F., Javier, A. et Witold, P. (2023). Derived Multi-population Genetic Algorithm for Adaptive Fuzzy C-Means Clustering. *Neural Process Lett* 55, 2023–2047. <https://doi.org/10.1007/s11063-022-10876-9>
 - [53] Kottaimalai, R., Vishnuvarthanan, G., Yu-Dong, Z., Pallikonda, R.M. et Arunprasath, T. (2021). "Brain Anomaly Prediction with the Intervention of Fuzzy Based Clustering and Optimization Techniques for Augmenting Clinical Diagnosis," 3rd International Conference on Advances in Computing, Communication Control

-
- and Networking (ICAC3N), Greater Noida, India, 2021, pp. 872-877, doi : 10.1109/ICAC3N53548.2021.9725563.
- [54] Moradi, M. et Hamidzadeh, J. (2023). Entropy-Based Fuzzy C-Ordered-Means Clustering Algorithm. *New Gener. Comput.* 41, 739–775 . <https://doi.org/10.1007/s00354-023-00229-y>
 - [55] Gomathi N., Geetha, A. (2021). An Efficient Hybrid Clustering and Feature Extraction Techniques for Brain Tumor Classification. *Webology*. 18. 556-581. 10.14704/WEB/V18I2/WEB18339.
 - [56] Sai Kishore D. V. , Murali Mohan Babu Y., Radhika K. et Kishore Reddy A. (2024). Fuzzy c-means based medical image retrieval for identifying most clinically relevant images. *Multimed Tools Appl* 83, 55283–55303. <https://doi.org/10.1007/s11042-023-17440-0>
 - [57] Kaixin Zhao, Yaping Dai, Zhiyang Jia et Ye Ji 2022, "General Fuzzy C-Means Clustering Strategy : Using Objective Function to Control Fuzziness of Clustering Results," in *IEEE Transactions on Fuzzy Systems*, vol. 30, no. 9, pp. 3601-3616, Sept. doi : 10.1109/TFUZZ.2021.3119240.
 - [58] Hanuman V., Deepa V. et Pawan K. T. (2021). A population based hybrid FCM-PSO algorithm for clustering analysis and segmentation of brain image. *Expert Systems with Applications*. Volume 167, 114121. ISSN 0957-4174. <https://doi.org/10.1016/j.eswa.2020.114121>.
 - [59] Ouchicha C., Ammor O. et Meknassi M. (2023). A new approach based on exponential entropy with modified kernel fuzzy c-means clustering for MRI brain segmentation. *Evol. Intel.* 16, 651–665. <https://doi-org.biblioproxy.uqtr.ca/10.1007/s12065-021-00689-5>
 - [60] Kumar, S.N., Fred, A., Lenin, F. et Sebastin, V. (2019). Suspicious Lesion Segmentation on Brain, Mammograms and Breast MR Images Using New Optimized Spatial Feature Based Super-Pixel Fuzzy C-Means Clustering. *Journal of Digital Imaging*, 322 – 335, 32(2), doi = 10.1007/s10278-018-0149-9.
 - [61] ÉTIENNE, B. (2023). Reconstruction D'objets 2D Fragmentés à l'aide de réseaux de neurones convolutifs siamois équivariants aux rotations et de matrices d'adjacence de contours.

-
- [mémoire, Université du Québec à Trois-Rivières]. eprint10762. <https://depot-e.uqtr.ca/id/eprint/10762/1/eprint10762.pdf>
- [62] Ali, N.A., El Abbassi, A. et Bouattane, O. (2023). Performance evaluation of spatial fuzzy C-means clustering algorithm on GPU for image segmentation. *Multimed Tools Appl* 82, 6787–6805. <https://doi.org/10.1007/s11042-022-13635-z>
- [63] Kumar, D., Agrawal R. K. et Kirar, S.J. (2019). "Intuitionistic Fuzzy Clustering Method with Spatial Information for MRI Image Segmentation," 2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), New Orleans, LA, USA, pp. 1-7, doi : 10.1109/FUZZ-IEEE.2019.8858865.
- [64] Kamarujjaman, Maitra, M. (2019). 3D unsupervised modified spatial fuzzy c-means method for segmentation of 3D brain MR image. *Pattern Anal Applic* 22, 1561–1571. <https://doi-org.biblioproxy.uqtr.ca/10.1007/s10044-019-00806-2>
- [65] Wu, C. et Wu, W. (2024). Master-slave hierarchy local information driven fuzzy C-means clustering for noisy image segmentation. *Vis Comput* 40, 865–897. <https://doi-org.biblioproxy.uqtr.ca/10.1007/s00371-023-02821-1>
- [66] Palani D., Venkatalakshmi K., Reshma Jabeen A. et Arun Bharath Ram V. M. (2019) . "Effective Detection of Diabetic Retinopathy From Human Retinal Fundus Images Using Modified FCM and IWPSO," IEEE International Conference on System, Computation, Automation and Networking (ICSCAN), Pondicherry, India, 2019, pp. 1-5, doi : 10.1109/ICSCAN.2019.8878786.
- [67] Ibtissem, C., Anissa, M., Abdenour, M. et Karim, M. (2020). "Adaptively Regularized Kernel-Based Fuzzy C-Means Clustering Algorithm Using Particle Swarm Optimization for Medical Image Segmentation". *Signal Processing : Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan, Poland, 2020, pp. 24-29, doi : 10.23919/SPA50552.2020.9241242.
- [68] William, F., Éloi, M., Yann-Gaël, G., Mourad, B. et Stefan, M. (2023). A mapping study of language features improving object-oriented design patterns, *Information and Software Technology*. Volume 160. DOI : <https://doi.org/10.1016/j.infsof.2023.107222>.

-
- [69] Shadi, A., Mohammed, S., Mahmoud, A.A., Yaser, J. et Brij, G. (2020). Parallel implementation for 3D medical volume fuzzy segmentation. *Pattern Recognition Letters*. 2020;130 :312-318. doi :10.1016/j.patrec.2018.07.026
 - [70] Wantanajittikul, K., Saiviroonporn, P., Saekho, S., Krittayaphong R. et Viprakasit V. (2021). An automated liver segmentation in liver iron concentration map using fuzzy c-means clustering combined with anatomical landmark data. *BMC Med Imaging* 21, 138. <https://doi.org/10.1186/s12880-021-00669-2>
 - [71] Bhimavarapu, U. (2024). Automatic liver tumor detection and classification using the hyper tangent fuzzy C-Means and improved fuzzy SVM. *Multimed Tools Appl* 83, 46201–46220. <https://doi.org/10.1007/s11042-023-17430-2>
 - [72] Gosain, A. et Dahiya, S. (2020). A New Robust Fuzzy Clustering Approach : DBKIFCM. *Neural Process Lett* 52, 2189–2210. <https://doi-org.biblioproxy.uqtr.ca/10.1007/s11063-020-10345-1>
 - [73] Wenke, Z., Zehua, W., Dong, J. et Xiyu, L. (2019). "A Kernel-Based Intuitionistic Fuzzy C-Means Clustering Using Improved Multi-Objective Immune Algorithm," in *IEEE Access*, vol. 7, pp. 84565-84579, 2019, doi : 10.1109/ACCESS.2019.2924957.
 - [74] Murthy, M.Y.B., Koteswararao, A. et Babu, M.S. (2022). Adaptive fuzzy deformable fusion and optimized CNN with ensemble classification for automated brain tumor diagnosis. *Biomed. Eng. Lett.* 12, 37–58. <https://doi-org.biblioproxy.uqtr.ca/10.1007/s13534-021-00209-5>
 - [75] Mashayekhi, Y., Nazerfard, E., Rahbar, A. et Haji Mahmood S. (2019). "The MinMax Fuzzy C-Means," 2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI), Tehran, Iran, 2019, pp. 210-215, doi : 10.1109/KBEI.2019.8734919.
 - [76] Simi Margarat, G., Hemalatha, G., Mishra, A., Shaheen, H., Maheswari, K., Tamijeselman, S., Pavan Kumar, U., Banupriya, V., Ferede et Alachew W. Early Diagnosis of Tuberculosis Using Deep Learning Approach for IOT Based Healthcare Applications. *Computational Intelligence et Neuroscience*. 9/28/2022, p1-9. 9p. DOI : 10.1155/2022/3357508.

-
- [77] Chakraborty, T., Banik, S.K., Bhadra, A.K. et Nandi, D. (2021). Dynamically learned PSO based neighborhood influenced fuzzy c-means for pre-treatment and post-treatment organ segmentation from CT images. *Computer Methods et Programs in Biomedicine*. 2021 ;202 :N.PAG. doi :10.1016/j.cmpb.2021.105971
 - [78] Singh, C., Ranade, S.K., Kaur, D. et Anu, B. (2024). A kernelized-bias-corrected fuzzy C-means approach with moment domain filtering for segmenting brain magnetic resonance images. *Soft Comput* 28, 1909–1933. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s00500-023-09379-z](https://doi-org.biblioproxy.uqtr.ca/10.1007/s00500-023-09379-z)
 - [79] Sriramakrishnan, P., Kalaiselvi, T., Somasundaram, K. et Rajeswaran, R. (2019). A rapid knowledge-based partial supervision fuzzy c-means for brain tissue segmentation with CUDA-enabled GPU machine. *Int J Imaging SystTechnol*. 2019 ;29 :547–560. [https ://doi.org/10.1002/ima.22335560](https://doi.org/10.1002/ima.22335560).
 - [80] Avinash, D., Vipin, R., Amrita, Shivani, J., Rajiv, K. et Sanjeev, K. P. (2022). Peripheral blood cell classification using modified local-information weighted fuzzy C-means clustering-based golden eagle optimization model. *Soft Comput* 26, 13829–13841. [https ://doi.org/10.1007/s00500-022-07392-2](https://doi.org/10.1007/s00500-022-07392-2).
 - [81] Dahiya, S. et Gosain, A. (2023). A novel type-II intuitionistic fuzzy clustering algorithm for mammograms segmentation. *J Ambient Intell Human Comput* 14, 3793–3808. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s12652-022-04022-5](https://doi-org.biblioproxy.uqtr.ca/10.1007/s12652-022-04022-5)
 - [82] Vela-Rincón, V.V., Mújica-Vargas, D. et Jose de Jesus R. (2022). J. Parallel hesitant fuzzy C-means algorithm to image segmentation. *SIViP* 16, 73–81. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s11760-021-01957-8](https://doi-org.biblioproxy.uqtr.ca/10.1007/s11760-021-01957-8)
 - [83] Solanki, R. et Kumar, D. (2023). Probabilistic intuitionistic fuzzy c-means algorithm with spatial constraint for human brain MRI segmentation. *Multimed Tools Appl* 82, 33663–33692. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-023-14512-z](https://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-023-14512-z)
 - [84] Verma, O.P. et Hooda, H. (2020). A novel intuitionistic fuzzy co-clustering algorithm for brain images. *Multimed Tools Appl* 79, 31517–31540. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-020-09320-8](https://doi-org.biblioproxy.uqtr.ca/10.1007/s11042-020-09320-8)

-
- [85] Jie, Z., Ge, Y., Can, G., Xizhao, W., Jianhua, D. et Witold, P. (2024). "Fuzzy Clustering Guided by Spectral Rotation and Scaling," in IEEE Transactions on Cybernetics, vol. 54, no. 11, pp. 6471-6484, doi : 10.1109/TCYB.2024.3450474.
 - [86] Natchapon, P., Sansanee, A., Nipon, T. et Chatpat, K. (2022). "Dental Fluorosis Segmentation Using Enhanced Quantum-Inspired Fuzzy Clustering Algorithm," 2022 37th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC), Phuket, Thailand, pp. 836-840, doi : 10.1109/ITC-CSCC55581.2022.9894942.
 - [87] Runxin, Z., Yu, D., Feiping, N., Rong, W., et Xuelong, L. (2024). "Unsupervised Deep Embedding for Fuzzy Clustering," in IEEE Transactions on Fuzzy Systems, vol. 32, no. 12, pp. 6744-6753. doi : 10.1109/TFUZZ.2024.3462545.
 - [88] Javad, Hassannataj, J., Hamid, S., Mohammad, G., Roohallah, A., Zahra, Alizadeh, S., Fereshteh, H., Edris, H., Danial, S. et Zulkefli, M. (2022). FCM-DNN : diagnosing coronary artery disease by deep accuracy fuzzy C-means clustering model[J]. Mathematical Biosciences and Engineering, 19(4) : 3609-3635. doi : 10.3934/mbe.2022167
 - [89] Thiagarajan, S.K. et Murugan, K. (2023). An exploration enhanced dynamic arithmetic optimization based modified fuzzy clustering framework for ischemic stroke lesion segmentation. Int. j. inf. tecnol. 15, 4389–4401. [https ://doi-org.biblioproxy.uqtr.ca/10.1007/s41870-023-01492-4](https://doi-org.biblioproxy.uqtr.ca/10.1007/s41870-023-01492-4)