

**République Algérienne Démocratique et Populaire**

**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique  
Université Abderrahmane MIRA - BEJAIA -**

**Département de Génie Electrique**



# **MEMOIRE DE FIN DE CYCLE**

**Présenté par**

**BOUCHAL Yasmina**

**Pour l'obtention du diplôme de**

## **MASTER ACADEMIQUE**

**Filière : ELECTRONIQUE**

**Option : TELECOMMUNICATION**

**Thème**

**INTELLIGENCE COMPUTATIONNELLE  
Application : Imagerie par Résonance Magnétique (IRM)**

**Devant le Jury composé de :**

**M<sup>r</sup> K. MOKRANI  
M<sup>me</sup> S .GHENAM**

**Encadreurs :**

**M<sup>r</sup> A. ALLICHE  
M<sup>r</sup> A. MEKHMUKH**

**Promotion : 2015-2016**



# Remerciements

*Avant tout, je remercie le grand Dieu Allah tout puissant, de m'avoir donné le courage et la patience pour accomplir ce modeste travail.*

*Mes vifs remerciements accompagnés de toute ma gratitude vont ensuite à mes encadreur **M ALLICHE** Abdenour et **M MEKHMOUKH** Abdenour, pour leurs conseils judicieux, leurs disponibilité et pour m'avoir suivie et orienté.*

*Je tiens aussi à remercier tous les membres de jury, **M MOKRANI** Karim président de jury, **M<sup>ne</sup> GHENNAM** Souhila examinatrice, certaine que leur jugement n'apportera que d'améliorations à ce travail.*

*Enfin mes remerciements s'adresseront aussi à tous ceux qui m'ont encouragé, aidé, famille d'abord, amies et collègues de la section des télécommunications ainsi que ceux d'automatique.*

# *Dédicaces*

*A mes très chers parents, que Dieu, le tout puissant puisse vous  
préserver, et vous accorder santé, longue vie et bonheur,*

*Rien au monde ne vaut les efforts fournis jour et nuit pour mon  
éducation et mon bien être, ceci est le fruit de vos sacrifices, je  
n'espère qu'être à la hauteur de vos attentes,*

*A toute ma famille, mes amies et surtout les étudiants des  
télécommunications,*

*A tous mes enseignants du primaire à l'université,*

*A tous les étudiants qui, j'espère pourrons bénéficier ne serait-ce  
qu'un peu de ce travail, et leur apportera un plus*

## **Table des matières**

<b>Introduction générale</b> .....	1
------------------------------------	---

### **Chapitre I : Etat de l'art de l'intelligence computationnelle**

I. Introduction.....	3
I.1. L'intelligence computationnelle .....	3
I.2. Historique .....	5
I.3. L'ère de l'intelligence computationnelle .....	5
I.4. Domaines d'application de l'intelligence computationnelle .....	5
I.5. Intérêt de l'intelligence computationnelle dans la classification .....	6
I.6. Caractérisation des approches de l'intelligence computationnelle .....	6
I.6.1. La logique floue .....	6
I.6.1.1. La pensée floue .....	7
I.6.1.2. L'idée de la logique floue .....	7
I.6.1.3. Définition de la logique floue .....	7
I.6.1.4. L'approche floue .....	8
I.6.1.5. La logique floue et la logique classique .....	8
I.6.2. Les réseaux neuronaux artificiels .....	9
I.6.2.1. Anatomie d'un neurone biologique .....	9
I.6.2.2. Modélisation du cerveau par le réseau de neurones artificiels .....	11
I.6.2.3. Le neurone formel.....	12
I.6.2.4. Les fonctions de transfert .....	12
I.6.2.5. Les réseaux de neurones .....	13
I.6.2.5.1. Apprentissage supervisé .....	13
I.6.2.5.2. Apprentissage non supervisé .....	14
I.6.2.6. Perceptron monocouche .....	14
I.6.2.7. Architecture du réseau multicouche .....	14
I.6.3. Le calcul évolutif (Algorithme génétique) .....	15
I.6.3.1. Les chromosomes .....	16
I.6.3.2. La reproduction dans un chromosome biologique et artificiel.....	17
I.6.3.3. L'algorithme génétique .....	17
I.6.3.4. Critère de terminaison classique utilisé dans l'algorithme génétique .....	17
I.6.3.5. Le codage .....	18
I.6.3.6. Le croisement ou Cross over .....	18
I.6.3.7. La mutation .....	19
I.7. Implémentation et synergies de l'intelligence computationnelle .....	20
I.8. Conclusion .....	21

### **Chapitre II : Segmentation de l'image par classifieur non supervisé**

II. Introduction .....	22
II.1. Généralités.....	22
II.1.1. Définition de l'image .....	22
II.1.2. Les types d'images .....	23

II.1.2.1.	Les images Matricielles .....	23
II.1.2.2.	Les images Vectorielles.....	23
II.1.3.	Numérisation de l'image .....	23
II.1.4.	Caractéristiques de l'image numérique .....	24
II.1.5.	Attributs de l'image .....	24
II.1.5.1.	Le pixel .....	24
II.1.5.2.	Image noir et blanc .....	24
II.1.5.3.	Image couleur .....	24
II.1.5.4.	Niveaux de gris .....	24
II.1.5.5.	L'histogramme .....	24
II.1.5.6.	La résolution d'une image .....	25
II.1.5.7.	Luminance ou brillance d'une image .....	26
II.1.5.8.	Le contraste .....	26
II.1.5.9.	Le bruit .....	27
II.1.5.10.	Le rehaussement .....	27
II.2.	Traitement de l'image .....	27
II.3.	Définition de la segmentation de l'image .....	27
II.4.	Objectifs de la segmentation .....	28
II.5.	Différentes approches .....	29
II.5.1.	Approche contours .....	29
II.5.2.	Approche région .....	29
II.6.	La classification .....	30
II.6.1.	La classification supervisée .....	30
II.6.2.	La classification non supervisée .....	30
II.7.	Les étapes d'une classification .....	31
II.8.	Le regroupement (clustering) .....	31
II.8.1.	Méthodes hiérarchiques .....	31
II.8.2.	Méthodes non hiérarchiques.....	31
II.9.	Dissemblance et distance ( <i>Similarité, dissimilarité</i> ) .....	31
II.10.	Segmentation par la méthode des k-means .....	33
II.10.1.	L'algorithme k-moyennes (k-means).....	33
II.11.	Segmentation floue d'images par classification de pixels .....	34
II.11.1.	Les C-moyennes (CM) .....	34
II.11.2.	Méthodes floues de classification .....	35
II.11.2.1.	Les C-moyennes floues (FCM) .....	35
II.11.3.	Paramètre de contrôle flou (m) .....	37
II.11.4.	Inconvénients de la méthode .....	37
II.12.	Conclusion .....	37

### Chapitre III : Classification approximative floue pour la segmentation d'image RM

III.	Introduction .....	38
III.1.	La théorie des ensembles flous (fuzzy set theory) .....	38
III.1.1.	Ensembles classiques et ensembles flous .....	38

III.1.2. Concept des sous-ensembles flous .....	39
III.1.2.1. Définition d'un sous-ensemble flou .....	40
III.1.2.2. La fonction d'appartenance .....	40
III.1.2.3. Caractéristiques des sous-ensembles flous .....	42
III.1.2.3.1. Le type .....	42
III.1.2.3.2. La hauteur .....	42
III.1.2.3.3. Le noyau .....	42
III.1.2.3.4. Le support .....	42
III.1.2.3.5. La cardinalité .....	42
III.1.2.3.6. La $\alpha$ -coupe .....	42
III.1.2.4. Opérations simples sur les sous-ensembles flous .....	43
III.1.2.5. Les probabilités et la théorie des sous-ensembles flous .....	44
III.1.2.6. La partition floue .....	44
III.1.2.7. Variable linguistique .....	45
III.1.2.8. Les règles floues et implication floue .....	46
III.1.2.9. Inférence floue .....	46
III.1.2.10. Système d'inférence flou .....	46
III.2. La théorie des ensembles approximatifs (rough set theory) .....	47
III.2.1. Notions de base sur les ensembles approximatifs .....	48
III.2.2. Système d'information et de classification .....	48
III.2.3. Système de décision .....	48
III.2.4. Relation d'indiscernabilité .....	48
III.2.5. Les approximations inférieures et supérieures .....	49
III.2.6. Qualité de l'approximation ou degré de dépendance, et la réduction .....	50
III.2.7. Noyau et réduction des attributs .....	50
III.3. L'hybridation des ensembles approximatifs avec les sous-ensembles flous .....	51
III.3.1. Les ensembles approximatifs flous (rough fuzzy sets) .....	51
III.3.2. L'algorithme RFCM .....	52
III.3.2.1. La fonction objectif .....	52
III.4. Conclusion .....	54

## Chapitre IV : Application à l'Imagerie par Résonance Magnétique (IRM)

IV. Introduction .....	55
IV.1. Segmentation des tissus cérébraux (MB, MG, LCR) .....	55
IV.2. L'anatomie cérébrale .....	55
IV.2.1. Le cerveau .....	56
IV.2.2. Le cervelet .....	56
IV.2.3. Le tronc cérébral .....	57
IV.3. Les tissus du cerveau .....	57
IV.3.1. Le liquide céphalo-rachidien (LCR) .....	57
IV.3.2. La matière grise (MG) .....	57
IV.3.3. La matière blanche (MB) .....	57
IV.4. L'Imagerie par Résonance Magnétique (IRM) .....	58
IV.5. L'observation du cerveau .....	59
IV.6. Analyse des résultats expérimentaux et discussion .....	59

## Table des matières

---

IV.6.1. Présentation de la base de données utilisée .....	59
IV.6.2. Etude d'images sans bruit.....	60
IV.6.3. Etude d'image avec différents bruits .....	60
IV.6.4. Critère d'évaluation choisit .....	61
IV.7. Conclusion.....	62
<b>Conclusion générale .....</b>	<b>63</b>

## Liste des figures

Figure 1.1 : position de l'intelligence computationnelle.....	4
Figure 1.2. Logique classique est un sous-ensemble de la logique floue.....	9
Figure 1.3 anatomie d'un neurone biologique .....	10
Figure 1.4 illustrant un synapse.....	10
Figure 1.5 analogie entre le réseau de neurones biologiques et artificiels.....	11
Figure 1.6 Modèle d'un neurone formel .....	12
Figure 1.7 les fonctions de transfert les plus adoptées .....	13
Figure 1.8 Perceptron monocouche à $n = 4$ entrées et $p = 3$ sorties.....	14
Figure 1.9 réseau de neurones multicouche .....	15
Figure 1.10 illustrant des chromosomes.....	16
Figure 1.11 les cinq niveaux d'organisation d'un algorithme génétique .....	18
Figure 1.12 montrant le processus de croisement .....	19
Figure 1.13 montrant l'opération de mutation.....	19
Figure 2.1 les types d'images (vectorielles et matricielle).....	23
Figure 2.2 : une image cérébrale avec son histogramme représentant la répartition des pixels en fonction de leur luminosité (niveau de gris).....	25
figure 2.3 montrant le résolution d'image .....	26
Figure 2.4 une image originale en haut avec son histogramme, et en bas la même image réglant sa luminosité à 24% .....	26
Figure 2.5 regroupement d'observation en clusters et le choix de leurs centres.....	33
Figure 3.1 Ensemble classique sur la gauche; logique booléenne, et un ensemble flou sur la droite; le niveau de gris indique le degré d'appartenance .....	39
Figure 3.2 les formes des fonctions d'appartenance.....	40
Figure 3.3 illustration des caractéristiques noyau, support, $\alpha$ -coupe et hauteur d'un sous ensemble flou .....	43
Figure 3.4 illustration sur les opérations sur les ensembles flous .....	44
Figure 3.5 Fonctions d'appartenance caractérisant les prédicats flous : <i>Froid, Moyen, Chaud et Très Chaud</i> .....	45
Figure 3.6 Structure d'un système d'inférence flou .....	47
Figure 3.7 carte Esquisse pour les concepts de la théorie des ensembles approximatifs .....	50
Figure 3.8 RFCM, $X_i$ est représenté par une frontière inférieure croustillante et une frontière floue.....	52
Figure 4.1 illustrant l'anatomie cérébrale .....	56
Figure 4.2 Coupe du cerveau mettant en évidence les trois matières principales .....	57

Figure 4.3 les trois coupes IRM du cerveau .....	59
Figure 4.4 résultat de la segmentation par le FCM d'une image sans bruit .....	60
Figure 4.5 résultat de la segmentation par RFCM d'une image sans bruit .....	60
Figure 4.6 résultat de la segmentation par le FCM d'une image bruitée par un bruit gaussien	60
Figure 4.7 résultat de la segmentation par le RFCM d'une image bruitée par un bruit gaussien .....	60
Figure 4.8 résultat de la segmentation par le FCM d'une image bruitée par le bruit Salt & Pepper .....	61
Figure 4.9 résultat de la segmentation par le RFCM d'une image bruitée par le bruit Salt & Pepper .....	61

### ***Liste des tableaux***

Tableau 4.1 Classification Rate (CR) obtenu par le FCM et le RFCM pour les différentes classes (MB, MG, LCR).....	62
--	----

### *Introduction générale*

Reproduire l'intelligence de l'être humain constitue sans aucun doute le rêve le plus passionnant de notre siècle, ce qui fait que la création de systèmes intelligents a été d'intérêt pour les scientifiques depuis de nombreuses années. L'homme a beaucoup appris des études sur les systèmes naturels. En utilisant ce qu'il a appris, il a développé des systèmes qui imitent le comportement des organismes vivants et ainsi, de nouveaux modèles algorithmiques pour résoudre des problèmes complexes.

L'intelligence computationnelle est une nouvelle branche de la science, et son développement remonte aux années 60 du siècle dernier, lorsque les premiers algorithmes de machines d'apprentissage ont été développés. Puis, dans les années 70 fondements de la théorie des ensembles et la logique floue ont été créés. Dans cette première période, des algorithmes génétiques et évolutionnaires ont été introduits. Dans les années 80, les bases pour la représentation des connaissances en utilisant des ensembles approximatifs ont également été créées.

Dans ce contexte, le mémoire présente une introduction à certains des paradigmes et technique de l'intelligence computationnelle, qui a pour méthodes :

- Le langage naturel, la capacité de raisonnement même en cas de manque d'information, en donnant des définitions de termes vagues, et permettant la construction d'une base de règles, sont les concepts de la logique floue.
- Le cerveau, avec ses capacités étonnantes de l'apprentissage, le stockage de la connaissance et le traitement de l'information, est une source d'inspiration pour le développement de réseaux de neurones artificiels (RNA).
- Le processus naturel de l'évolution des espèces, la sélection naturelle et d'autres opérateurs génétiques sont une source d'inspiration des algorithmes génétiques.

L'habileté de remplacer les capacités visuelles humaines par une machine est très importante, et en est une raison évidente, vu le fait que la reconnaissance de forme et la classification des objets de l'image, sont l'une des zones les plus activement poursuivis dans le domaine des sciences de l'image et de l'ingénierie.

Une multitude de méthodes de segmentation sont proposées dans la littérature, voir, la segmentation par approche contour et approche région, et nous, nous intéresserons à la segmentation par approche classification appliquée sur l'ensemble des valeurs des pixels.

La recherche d'une méthode performante, pour une application quelconque passe par la comparaison de quelques méthodes déjà existantes, utilisées et disponibles, et par l'amélioration des performances de ces méthodes de segmentation en trouvant ses variantes ou en faisons une fusion, combinaison, hybridation de deux méthodes, ce qui est le sujet et l'objet

de ce mémoire, ces méthodes sous forme d'algorithme sont censées donner des résultats plus optimales. Que donnerait la combinaison des méthodes de l'intelligence computationnelle à la segmentation ? Peut-on bénéficier des hybridations de ces méthodes dans la classification ?

Au cours des dernières années, de nombreuses techniques hybrides donnent des algorithmes performants s'appliquant dans différents domaines. Dans ce mémoire nous aborderons une de ces hybridations, celle des ensembles approximatifs avec les ensembles flous. Alors comment pourrions-nous appliquer une telle hybridation qui donne des résultats de segmentation plus précis appliqués sur des images de nature complexes telle que celle par résonance magnétique, qui sont censés à leur tour aider au diagnostic médical.

Le choix de ces images par résonance magnétique est basé sur le fait qu'elles permettent l'étude du cerveau, et permettent au chirurgien de visualiser la pathologie, et puis elles sont les seules images qui permettent de voir à l'intérieur du cerveau.

Ce manuscrit est organisé comme suit :

Le premier chapitre donne les bases biologiques des méthodes les plus pondérantes de l'intelligence computationnelle et leurs analogues artificiels.

Le second chapitre introduit des notions de base sur l'image numérique, et les principales méthodes de segmentation d'images, en présentant des algorithmes dédiés à la tâche de classification et qui consiste à partitionner l'image en région homogènes.

Le troisième chapitre est dédié à un algorithme hybride de classification, précédé par des propriétés importantes des ensembles flous et approximatifs.

Nous parlerons dans le dernier chapitre des résultats de comparaison entre nos deux algorithmes appliqués sur l'IRM en vue d'une classification des tissus du cerveau.

Et nous finirons avec une conclusion nous permettons d'assembler les résultats obtenus et de conclure ce travail par quelques perspectives.

## I. Introduction :

L'intelligence, un mot employé, par le sens commun, pour désigner une propriété essentiellement humaine. Elle est toujours associée aussi à des êtres dotés de certains états mentaux. La littérature contient de nombreuses définitions différentes de l'intelligence, mais la plupart d'entre elles sont abouties à la conclusion que l'intelligence est la capacité d'adaptation à de nouvelles tâches et aux conditions de vie, ou de la manière dont les humains traitent l'information et résolu les problèmes. L'intelligence est aussi la capacité à comprendre. Elle est influencée par des facteurs héréditaires.

Les machines intelligentes construites par l'humain peuvent être programmées pour imiter un peu de son intelligence. D'où le terme intelligence artificielle, qui est une adaptation de la manière de la prise de décision de la pensée humaine, en utilisant le système d'informatique. Faire face à d'important problèmes dans notre vie quotidienne, qui ne peuvent pas être résolus en utilisant les approches mathématique et analytiques conventionnelle, des algorithmes fournissant des solutions pour tacler ces problèmes ont été développés, ces algorithmes sont inspirés par les processus de la prise de décision dans le système naturel (imiter le système nerveux de l'humain dans la prise de décision), elle est réparti en intelligence artificielle douce et l'intelligence artificielle dure (soft et hard AI). Cette dernière cherche la netteté et la clarté des solutions et nécessite beaucoup de temps de calcul. En revanche, l'intelligence artificielle douce fournit des solutions à plusieurs problèmes tout simplement très compliqués à être adresser aux approches de la dure intelligence artificielle, et réclame des méthodes plus flexibles. L'intelligence computationnelle est une nouvelle branche de la douce intelligence artificielle, qui, principalement, à voir avec des méthodes particulières, y compris la logique floue, les réseaux de neurones, les algorithmes génétiques, les ensembles approximatifs...etc, qui appartiennent à un domaine qui est en développement rapide. Elle est composée de plusieurs théories et d'approches.

Dans ce premier chapitre, nous présentons dans un premier temps une initiation à l'intelligence computationnelle puis sa définition. Ensuite, nous présentons un aperçu de ses différentes techniques et méthodes les plus pondérées et leur concept de base ainsi que les différentes combinaisons synergiques.

### I.1. L'intelligence computationnelle :

L'intelligence computationnelle est associée au soft computing « *traduction française, l'informatique douce* », qui est caractérisé par l'utilisation de solutions inexactes pour des tâches difficiles d'un point de vue computationnel. Cela encourage l'intégration des techniques et outils du soft computing dans les applications quotidiennes et avancées [43]. Ces outils sont utilisés indépendamment et conjointement en fonction du type du domaine d'applications. Elle, selon le professeur Zadeh, est « *une approche émergente à l'informatique, qui est parallèle à la remarquable capacité de l'esprit humain à raisonner et à apprendre dans un environnement d'incertitude et d'imprécision* » [13]. Le soft computing exploite la tolérance pour l'imprécision, l'incertitude et la vérité partielle pour atteindre la robustesse, la tractabilité, et un faible coût de la solution. Le terme intelligence computationnelle [28] tel que défini par Zadeh, est une combinaison de l'informatique douce et le calcul numérique.

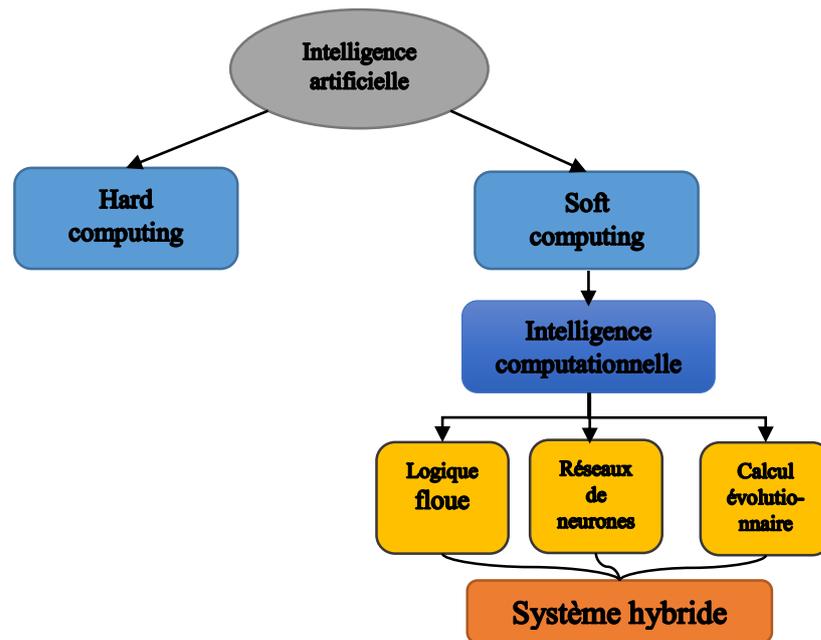


Figure 1.1 : position de l'intelligence computationnelle

En général, l'informatique douce offre des opportunités intéressantes pour modéliser l'ambiguïté et la pensée humaine dans des situations difficiles et incertaines de la vie réelle. Un grand nombre de problèmes du monde réel sont de plus en plus exigeant et stimulant. Par conséquent, une **fusion** constructive de toutes les méthodes possibles est certainement nécessaire dans le développement de solutions[30], en effet, la combinaison particulière de ses méthodes a donnée ce qui est connu « systèmes neuro floue », de tels systèmes sont des produits de consommation, allant des climatiseurs et des machines à laver, aux photocopieuses, les caméscopes et de nombreuses applications industrielles. Dans les chapitres suivants, nous parlerons de la fusion des ensembles floue avec les ensembles approximatifs (rough sets).

Jusqu'à maintenant, il n'y a pas de définition communément acceptée de l'intelligence computationnelle. Pour BEZDEK (1994), « *un système est appelé informatiquement intelligent s'il traite les données de bas niveau tels que des données numériques, si, il a une composante de reconnaissance des formes et s'il n'utilise pas des connaissances aussi exacte et complète que celle de l'intelligence artificielle* » [28].

Mais en général, l'intelligence computationnelle est un ensemble de méthodes de calculs inspirés de la nature et des approches pour résoudre les problèmes complexes du monde réel, dont la modélisation mathématique traditionnelle (classique) peut être inutile pour la raison que les processus pourraient être trop complexes et incertain. En effet, de nombreux problèmes de la vie ne peuvent pas être traduits en langage binaire (valeurs uniques de 0 et 1) pour les ordinateurs afin de les traiter. L'intelligence computationnelle fournit donc des solutions pour ces problèmes. Ses techniques sont en mesure de faire des prédictions ou des décisions concernant des événements futurs [29].

Les méthodes utilisées sont proches de la manière du raisonnement de l'être humain, à savoir qu'il utilise les connaissances non exacte et non complète. L'intelligence computationnelle utilise donc une

combinaison de cinq principales techniques complémentaires : [29] La logique floue qui permet à l'ordinateur de comprendre le langage naturel, [33] des réseaux de neurones artificiels qui permettent au système d'apprendre des données expérimentées en opérant comme celle biologique, le calcul évolutif qui est basé sur le processus de sélection naturelle, la théorie de l'apprentissage et des méthodes probabilistes qui aide à faire face aux incertitudes d'imprécision [28].

Il faut souligner que le sujet d'intérêt de l'intelligence computationnelle couvre non seulement les techniques individuelles, mais aussi leurs diverses combinaisons. Une société internationale appelée IEEE Computational Intelligence Society, organise de nombreuses conférences dans le domaine de l'intelligence computationnelle, d'ailleurs, elle publie trois revues prestigieuses dans ce domaine, à savoir IEEE Transactions on Neural Networks, IEEE Transactions on Fuzzy Systems et IEEE Transactions on Evolutionary Calcul. [32]

### **I.2. Historique :**

Lotfi Zadeh était celui qui a contribué le plus dans le domaine de la logique floue, et c'est le développeur des ensembles flous [Zadeh 1965]. A partir de là, jusqu'à ce que les systèmes flous des années 1980 était un champ actif, produisant des noms tels que Mamdani, Sugeno, Takagi et Bezdek. Ensuite, les systèmes flous ont également connu un âge sombre dans les années 1980, mais ont été relancés par des chercheurs japonais à la fin des années 1980. Aujourd'hui, il est un domaine très actif avec de nombreuses applications réussies, en particulier dans les systèmes de contrôle. En 1991, Pawlak introduit la théorie des ensembles approximatifs à l'informatique, où le concept fondamental est le constat d'une approximation inférieure et supérieure à l'espace d'entrée. Tous les éléments dans le l'approximation inférieur ont une pleine adhésion, tandis que les éléments de frontière (ces éléments entre le rapprochement supérieur et inférieur) appartiennent à l'ensemble à un certain degré [2].

### **I.3. L'ère de l'intelligence computationnelle :**

Au cours des dernières années, l'IC a connu une croissance rapide de la visibilité et de l'importance. Son noyau est la conception et l'utilisation de systèmes intelligents, qui a commencé à se cristalliser dans les années 1980 [28].

- première utilisation du terme (dans son contexte actuel) en 1990.
- la naissance de l'IC est attribuée au Congrès mondial de l'IEEE sur l'intelligence computationnelle en 1994.
- premier texte sur l'intelligence computationnelle en 1996.
- en 1997, IEEE transactions en tenant compte des trois champs: réseaux de neurones, systèmes flous, et de calcul évolutionnaire.
- deuxième congrès mondial de l'IEEE sur IC dans l'ancrage en 1998.
- société de réseaux neuronale en 2002, la société de l'intelligence computationnelle en 2006.
- les systèmes hybrides sont devenus communs.

#### **I.4. Domaines d'application de l'intelligence computationnelle :**

Chaque méthode composante de l'intelligence computationnelle a des domaines d'application pour lesquelles elle est particulièrement bien adaptée. Comme dans le contrôle, la prise de décision, l'analyse d'ADN...etc. Gardez à l'esprit que les domaines d'application peuvent se chevaucher; autrement dit, un problème de regroupement (clustering) donné peut être soit résoluble par un réseau de neurones ou d'un système flou par exemple, mais avec différents niveaux de performance. Notons que des combinaisons des méthodes peuvent produire des résultats différents [28].

#### **I.5. Intérêt de l'intelligence computationnelle dans la classification:**

Les problèmes de classification sont très fréquents dans les applications médicales, où plusieurs entrées telles que des images médicales, les données cliniques, ou d'autres intrants médicaux devraient être utilisés pour le diagnostic, le pronostic, ou d'autres fins. A titre d'exemple, dans une application médicale typique, les classes peuvent représenter simplement un diagnostic positif ou négatif du cancer ou de la possibilité d'existence d'une tumeur dans une certaine partie d'une image médicale produite. Pour obtenir un classifieur, souvent, un ensemble d'observations doit être fourni. Sur cette base, une méthode de l'intelligence computationnelle devrait être en mesure de se former de telle sorte que la classe correcte pour de nouvelles observations, peut être déterminée. D'autre part, il est également possible que les données de l'ensemble d'observations comprennent un ensemble d'observations sans la bonne classe, et l'algorithme est supposé déterminer les classes, en classant les observations les plus proches d'une classe; ceci est connu comme le clustering que nous aborderons dans les chapitres suivants.

#### **I.6. Caractérisation des approches de l'intelligence computationnelle :**

Les techniques et approches de l'intelligence computationnelle englobent divers paradigmes dédiés à la résolution approximative des problèmes du monde réel dans la prise de décision, la classification des formes, et l'apprentissage. Ceux qui sont au premier rang de ces paradigmes, sont la logique floue, les réseaux de neurones, les algorithmes génétiques, et les ensembles approximatifs.

##### **I.6.1. La logique floue :**

Jusqu'à une date récente, l'intelligence artificielle a eu un impact limité sur les applications industrielles, parce qu'elle a mis l'accent, sur le traitement symbolique de la connaissance, par opposition à la modélisation numérique utilisée traditionnellement dans les sciences de l'ingénieur. Plus récemment on a assisté à un retour du numérique dans ces problèmes d'intelligence artificielle, avec les réseaux de neurones et la logique floue. Cette dernière est plus conforme à l'intelligence artificielle symbolique, qui met en avant la notion de raisonnement.

La logique floue a connu un intérêt important dans la communauté scientifique au cours des dernières années. L'une des raisons principales, est l'énorme succès des équipements domestique produits par l'industrie japonaise, utilisant des régulateurs flous.

Certains scientifiques rapportent que la logique floue a permis de découvrir la manière de la pensée humaine et qu'elle « fournit la puissance mathématique pour l'émulation des hautes fonctions cognitives- la pensée et le processus de perception ». Nous considérons que ce genre d'affirmation est trompeur, parce qu'il n'y a aucune évidence d'une base biologique de la logique floue.

#### **I.6.1.1. La pensée floue :**

*Enoncé:* Dans la logique floue ce n'est pas la logique qui est floue, mais plutôt la logique qui est utilisée pour décrire le flou. La logique floue est la théorie des ensembles flous, des ensembles qui étalonnent l'imprécision. La logique floue est basée sur l'idée que toutes les choses admettent des degrés. Température, la hauteur, la vitesse, la distance, la beauté qui viennent tous sur une échelle mobile.

Une telle échelle mobile rend souvent impossible de distinguer les membres d'une classe des non-membres.

La logique floue reflète la façon dont les gens pensent. Elle tente de modéliser notre sens des mots, notre prise de décision et notre bon sens. Par conséquent, elle conduit à de nouveaux systèmes intelligents, plus humains [25].

#### **I.6.1.2. L'idée de la logique floue**

Comme La science s'appuie sur la notion de mesure, la question qui se pose est : comment représenter les valeurs non mesurables? Comment représenter ce qui est incertain ? Comment représenter les termes du langage humain ? Les descriptions linguistiques d'un système sont souvent vagues. Mais le flou n'est pas imprécis. Si une donnée n'est pas connue précisément, elle peut être exprimée par un intervalle précis. Cet intervalle est un ensemble de valeurs possible pour la donnée [14].

#### **I.6.1.3. Définition de la logique floue :**

La logique floue est une technique de résolution de problèmes très puissants avec une large applicabilité dans le contrôle et la prise de décision. Elle est très utile lorsque le modèle mathématique du problème à traiter n'existe pas ou existe mais difficile à implémenter, ou il est trop complexe pour être évalué assez rapidement pour des opérations en temps réel. Ou bien lorsque des experts humains sont disponibles pour fournir des descriptions subjectives du comportement du système avec des termes en langage naturel. La logique floue est aussi supposée de travailler dans les situations où il y a de large incertitude et des variations inconnues dans les paramètres et la structure du système.

En effet, le mode de raisonnement en logique floue est plus intuitif que la logique classique. Il permet aux concepteurs de mieux appréhender les phénomènes naturels, imprécis et difficilement modélisables en s'appuyant sur la définition de règles et de fonctions d'appartenance.

La définition de Zadeh :

« *Fuzzy logic is determined as a set of mathematical principles for knowledge representation based on degree of membership rather than on crisp membership of classical binary logic.* »

#### **I.6.1.4. L'approche floue :**

Il existe plusieurs approches différentes pour le raisonnement ayant une connaissance imparfaite ou imprécise, y compris les systèmes à base de règles floues qui sont basés sur la théorie des ensembles flous et la logique floue.

Au cœur d'un système tel sont une base de connaissances et une procédure d'inférence: [31] [6]

1. La base de connaissances est composée de la production floue « si-alors », les règles qui conceptualisent la connaissance du domaine et des fonctions d'appartenance définissant les ensembles flous associés aux termes linguistiques utilisés dans les règles floues.
2. La procédure d'inférence utilise ces connaissances stockées pour formuler un mappage à partir d'une entrée donnée (par exemple dans le classement, les conditions indiquées par les valeurs d'attributs) à une sortie (par exemple dans la classification, une conclusion dénotés par une étiquette de classe).

Il est à noter qu'il faut capturer l'essentiel du problème, en laissant de côté tous les facteurs qui pourrait être arbitraire [6].

La puissance de la logique floue vient de sa capacité à décrire un phénomène ou processus particulier de façon linguistique, puis de représenter ce phénomène par un faible nombre de règles. Les connaissances dans un système flou sont contenues dans les règles et dans les ensembles flous, qui contiennent des descriptions générales des propriétés du phénomène en question.

#### **I.6.1.5. La logique floue et la logique classique :**

En outre, basé sur le même principe que précédemment, la logique floue est une extension de la logique classique, elle vise à modéliser les modes imprécis du raisonnement qui jouent un rôle important, dans la capacité humaine de prendre des décisions rationnelles dans un environnement incertain et imprécis, mais ceci n'est pas pris en compte dans la logique classique dont toute proposition ayant une valeur de 0 est fausse ou de 1 est vraie, en logique floue, une valeur entre 0 et 1 est acceptable comme le degré de vérité d'une proposition particulière ( $x$  appartient au sous-ensemble flou). Ces degrés de vérité ou de validité, représentent l'incertitude et l'imprécision dans les informations du monde réel.

Selon la logique floue, le raisonnement exact est un cas limite du raisonnement approximatif; tout n'est qu'un degré.

Ainsi, la logique floue permet à un ordinateur de modéliser le monde réel de la même façon que les humains, elle peut fournir un modèle plus réaliste de la vérité en décrivant des propositions pour qu'elle

soit «moitié vraie», «presque fausse,» ou «tout à fait vraie», c'est pour dire qu'elle adapte le concept de vérité partielle : des valeurs entre complètement vraies et complètement fausses sont admises, par opposition à une description nette et binaire, soit vraie ou fausse [1]. Son importance provient du fait que le raisonnement humain est approximatif, puisque on supporte des modes de raisonnement approximatifs plutôt qu'exactes.

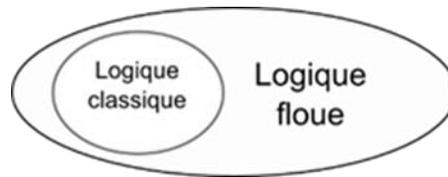


Figure 1.2. Logique classique est un sous-ensemble de la logique floue

Le fait que la logique floue traite des modes approximatifs plutôt que précis du raisonnement, implique que, en général, les chaînes de raisonnement sont courtes et la rigueur ne joue pas un rôle important comme dans le cas de la logique classique.

### **I.6.2. Réseaux neuronaux artificiels [46][45]:**

Certains des premiers travaux en intelligence artificielle se sont inspirés des résultats fondamentaux des neurosciences, en particulier de l'hypothèse que l'activité mentale consiste principalement en l'activité électrochimique du réseau de cellules du cerveau, les neurones. Ces travaux se sont donné pour but de créer des réseaux de neurones artificiels. Nicolas Rashvsky (1936, 1938) a été le premier à appliquer des modèles mathématiques à l'étude du système nerveux

#### **I.6.2.1. Anatomie d'un neurone biologique :**

Le neurone, ou cellule nerveuse, est l'unité fonctionnelle du système nerveux. Rien que dans le cerveau humain, on trouve 10 milliards d'unités de traitement de l'information de base, appelées neurones, et 60 trillions de connexions, les synapses. Sa configuration cellulaire spécifique le rend capable de générer, de transmettre et/ou de recevoir des informations sous forme de signaux électriques (influx nerveux) [45] [39].

Une cellule nerveuse biologique ou un neurone typique représente trois régions distinctes: le corps cellulaire, ou *soma*, les dendrites et les axones. Chacune de ces différentes régions joue un rôle bien défini dans le transport de l'information.

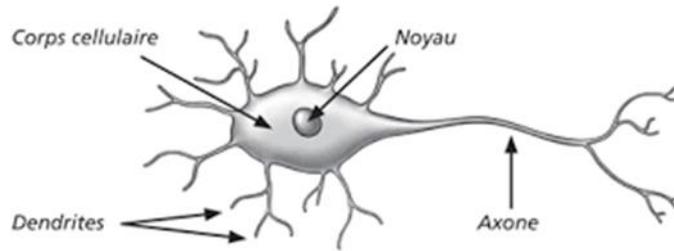


Figure 1.3 anatomie d'un neurone biologique

*Le corps cellulaire* : contient le noyau de la cellule et le cytoplasme, là où sont produites les molécules qui servent au fonctionnement de la cellule. La forme du corps cellulaire est variable suivant le type de neurone; elle peut être pyramidale, ovoïde ou sphérique. Les impulsions électriques arrivent sur les dendrites, s'y propagent et sont intégrées au niveau du soma. Ce dernier génère une réponse qui se propage dans l'axone jusqu'au neurone suivant.

*Les dendrites* : Ce sont des fibres issues du corps cellulaire qui se divisent comme les branches d'un arbre, recueillent l'information en provenance d'autres neurones et l'acheminement vers le corps de la cellule. C'est la somme de ces courants électriques, positifs et négatifs, transmise au niveau des dendrites qui déterminera si un potentiel d'action (courant électrique positif) sera amorcé au niveau du segment initial.

*L'axone* : Généralement très long et unique, 100 fois le diamètre d'un corps cellulaire. Cet axone conduit l'information du corps cellulaire vers d'autres neurones, avec qui il fait des connexions appelées synapses. Un neurone est connecté avec 10 à 100 000 autres neurones par des synapses, c'est à leur niveau que les informations, ou les signaux sont transmis par une réaction électrochimique complexe.

Chaque neurone effectue un traitement local. Il collecte les signaux issus des dendrites et leur fait la somme. Si l'amplitude résultante dépasse un certain seuil interne, un signal est envoyé à travers l'axon vers d'autres neurones.

La notion de synapse explique la transmission des signaux entre un axone et une dendrite. Au niveau de la jonction (c'est à dire de la synapse), il existe un espace vide à travers lequel le signal électrique ne peut pas se propager.

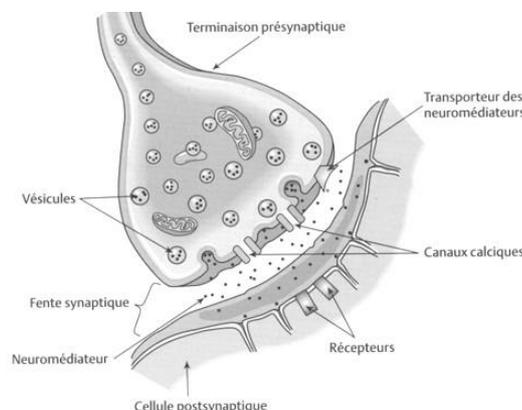


Figure 1.4 illustrant un synapse

La transmission se fait alors par l'intermédiaire de substances chimiques, les neuro-médiateurs. Quand un signal arrive au niveau du synapse, il provoque l'émission de ces neuro-médiateurs qui vont se fixer sur des récepteurs de l'autre côté de l'espace inter-synaptique. Quand suffisamment de molécules se sont fixées, des signaux électriques sont émis de l'autre côté et on a donc une transmission [45]. Ces derniers contrôlent l'activité du cerveau [37]. En réponse à la configuration de stimulation, les neurones montrent des changements à long terme dans la force de leurs connexions. Neurones peuvent également former de nouvelles connexions avec d'autres neurones. Même des collections entières de neurones peuvent parfois migrer d'un endroit à l'autre. Ces mécanismes forment la base de l'apprentissage dans le cerveau [25]. L'essentiel du traitement des informations a eu lieu dans le cortex cérébral.

Un réseau de neurones peut être défini comme un modèle de raisonnement basé sur le cerveau humain, car en utilisant plusieurs neurones simultanément, celui-ci peut exercer ses fonctions beaucoup plus rapide que les ordinateurs les plus rapides qui existent aujourd'hui [25]

Les informations sont traitées et stockées dans le réseau de neurones à travers l'ensemble du réseau global ( il y a des parties dans cerveau qui sont souvent stimulées plus que d'autres parties, ce qui fait que certaines connexions entre les neurones conduisant à la bonne réponse sont renforcées, tandis que celles qui conduisent à la mauvaise réponse, affaiblissent). L'apprentissage est une caractéristique fondamentale et essentielle des réseaux de neurones biologiques, car ces derniers ont la capacité d'apprendre par l'expérience pour améliorer les performances, en conséquence, toutes ces caractéristiques ont conduits à des tentatives pour émuler un réseau neuronale biologique dans un ordinateur.

### I.6.2.2. Modélisation du cerveau par le réseau de neurones artificiels :

Les réseaux neuronaux artificiels (RNA ou en Anglais ANN) sont analogues électriques des réseaux neuronaux biologiques. Un réseau neuronal artificiel comprend un certain nombre de processeurs très simples et très fortement interconnectés, également appelés neurones qui sont reliés par des liens pondérés passant des signaux d'un neurone à l'autre. Chaque neurone reçoit un certain nombre de signaux d'entrée par l'intermédiaire de ses connexions; cependant, elle ne produit jamais plus d'un seul signal de sortie. Le signal de sortie est transmis à travers la connexion sortant. Celle-ci, à son tour, se divise en un certain nombre de branches qui transmettent le même signal (le signal n'est pas divisé entre les branches). Les branches sortantes terminent les connexions entrantes d'autres neurones dans le réseau. La figure 1 montre l'analogie entre le réseau de neurones biologiques et artificiels.

Biological neural network	Artificial neural network
Soma	Neuron
Dendrite	Input
Axon	Output
Synapse	Weight

Figure 1.5 analogie entre le réseau de neurones biologiques et artificiels

### I.6.2.3. Le neurone formel :

En 1943, deux chercheurs américains, Mac Culloch et Pitts, ont donné naissance au premier modèle mathématique de neurone biologique, qu'ils ont appelé : *neurone formel*.

Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat  $n$  de cette somme est ensuite transformé par une fonction de transfert  $f$  qui produit la sortie  $a$  du neurone.

Un poids d'un neurone artificiel représente l'efficacité d'une connexion synaptique. Un poids négatif vient inhiber une entrée, alors qu'un poids positif vient l'accentuer.

La structure de base d'un neurone peut être théoriquement modélisée comme le montre la figure ci-dessous.

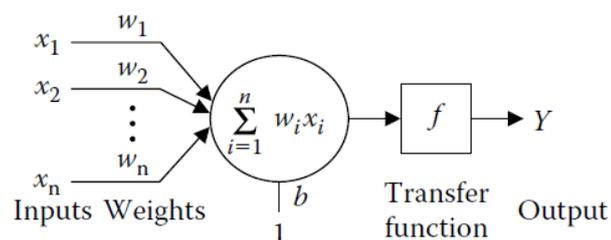


Figure 1.6 Modèle d'un neurone formel

La figure nous montre le modèle d'un seul neurone, où  $X = \{x_i, i = 1, 2, \dots, N\}$  représente les entrées du neurone qui peuvent être binaire ou réelles [38] et  $Y$  représente la sortie. Chaque entrée est multiplié par son poids  $w_i$ , un biais  $b$  est associé à chaque neurone, et leur somme passe par une fonction de transfert  $f$ . Par conséquent, la relation entre l'entrée et la sortie peut être décrit comme suit.

$$Y = f \left( \sum_{i=1}^n w_i x_i + b \right) \quad (1)$$

Son principe général est de retourner une information en sortie à partir de plusieurs informations en entrée. Le rôle d'un neurone est de fournir une réponse  $y$  entre 0 et 1 à partir de  $Y$ . Lorsque la réponse est proche de 1, nous dirons que le neurone est actif et pour une réponse proche de 0, le neurone est dit inactif.

En gros, le neurone est déclenché lorsqu'une combinaison linéaire des valeurs d'entrées qu'il reçoit dépasse un certain seuil à partir duquel la sortie commute entre les deux classes: il implémente donc un classificateur linéaire [39] car il divise l'espace d'entrée linéairement en deux sous-espaces: négatifs et positifs [12].

### I.6.2.4. Les fonctions de transferts :

Une gamme de fonctions de transfert ont été développés pour traiter les entrées pondérées et biaisés. Quatre des fonctions de transfert de base largement adoptées pour le traitement d'images médicales sont illustrés à la figure 1.7.

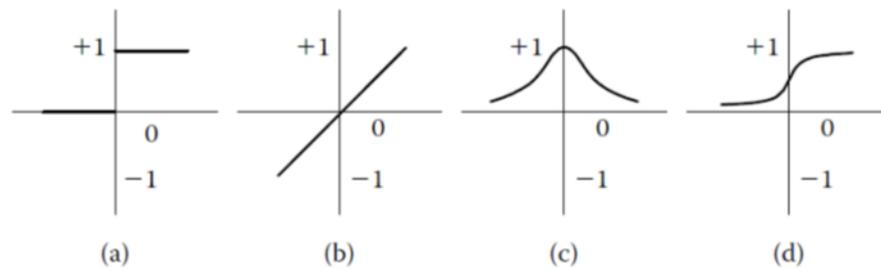


Figure 1.7 les fonctions de transfert les plus adoptées

(a) l'échelon ; (b) fonction linéaire ; (c) La fonction de base radiale « Gaussienne » ; (d) sigmoïde

La fonction échelon est souvent utilisée dans les neurones de prise de décision pour les tâches de classification et de reconnaissance des formes.

La fonction sigmoïde transforme l'entrée, ce qui peut avoir une valeur comprise entre plus et moins l'infini, en une valeur raisonnable dans la gamme entre 0 et 1. Les neurones avec cette fonction sont utilisés dans les réseaux de back-propagation.

La fonction d'activation linéaire fournit une sortie égale au neurone d'entrée pondéré. Neurones avec la fonction linéaire sont souvent utilisés pour linéaire approximation [25].

Par sélection de la fonction de transfert et la connexion des neurones, les différents réseaux de neurones peuvent être construits de manière à être formés pour produire des sorties spécifiées.

#### **I.6.2.5. Les réseaux de neurones :**

Un réseau de neurones artificiel est un maillage de plusieurs neurones, généralement organisé en couches, autrement, c'est une collection de tels neurones électriques connectés entre elles, de [36] sorte que les signaux de sortie des neurones deviennent des signaux d'entrées dans d'autres neurones, et les propriétés du réseau sont déterminées par sa topologie et les propriétés des neurones. L'application la plus courante d'un réseau neuronal artificiel est dans l'apprentissage de la machine. Dans un problème d'apprentissage, les poids et / ou non-linéarités dans un réseau neuronal artificiel sont soumis à un cycle d'adaptation. Le cycle d'adaptation est nécessaire pour mettre à jour les paramètres du réseau, jusqu'à ce qu'un état d'équilibre soit atteint.

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. Le RNA supporte les deux classes d'algorithme d'apprentissage supervisé et non supervisé [13].

##### **I.6.2.5.1. Apprentissage supervisé :**

Dans l'apprentissage supervisé on veut qu'à une entrée, corresponde une sortie préalablement définie. Une erreur est calculée entre le vecteur des sorties désirées et le vecteur des sorties calculées par le réseau. L'algorithme d'apprentissage modifie les poids du réseau de façon que cette distance soit réduite jusqu'à une valeur acceptable. Cette approche n'est donc possible que quand la conduite désirée

est connue *a priori*. Il consiste en l'existence d'un échantillon sur lequel le réseau apprend (s'entraîne) à reconnaître les formes [37].

Le perceptron multicouche est un exemple de réseau à apprentissage supervisé.

#### I.6.2.5.2. Apprentissage non supervisé :

Dans cet apprentissage on veut construire un réseau dont on ne connaît pas *a priori* la sortie correspondant à des entrées données. On dispose d'un ensemble de données, représentées par des vecteurs, et on cherche à les regrouper, selon des critères de ressemblance qui sont inconnus *a priori*. C'est au réseau de découvrir ces ressemblances entre ces données [38]. Par voie de conséquence, le réseau s'auto organise, en vue d'être capable de découvrir la forme à partir des données fournies et sans aide extérieure [34].

#### I.6.2.6. Perceptron monocouche

Le perceptron monocouche est la forme la plus simple du perceptron, et est composé de  $p$  neurones disposés en une seule couche, en parallèle, chacun des  $p$  neurones étant connecté aux  $n$  variables d'entrée. Globalement, ce réseau dispose donc de  $n$  entrées et de  $p$  sorties, chaque neurone renvoyant sa sortie. Le perceptron est En théorie, chacun des neurones du réseau peut avoir une fonction d'activation différente. En pratique, ce n'est généralement pas le cas [12] [46].

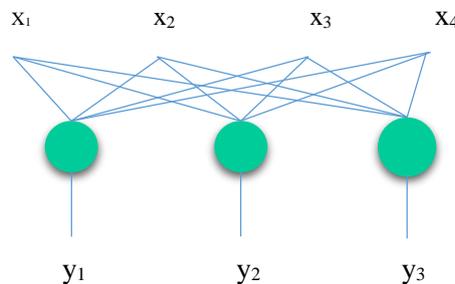


Figure 1.8 Perceptron monocouche à  $n = 4$  entrées et  $p = 3$  sorties

#### I.6.2.7. Architecture du réseau multicouche

Les capacités d'un seul neurone sont limitées. L'implantation de fonctions complexes nécessite l'intégration de plusieurs neurones sous forme d'un réseau à topologie spécifique. Le réseau à multicouche est organisé, comme son nom l'indique, en couches. Chaque couche comporte plusieurs neurones. Chaque neurone représente une unité de calcul autonome reliée aux neurones de la ou les couches précédentes.

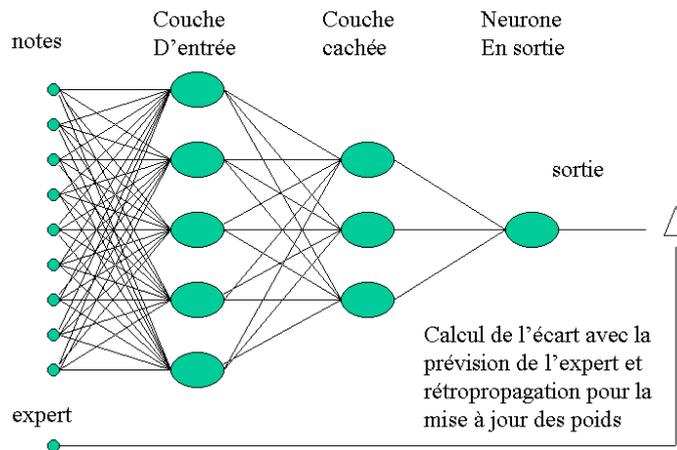


Figure 1.9 réseau de neurones multicouche

Le réseau que représente la figure-ci dessus comporte trois couches. La couche d'entrée (inputs), une couche de sortie comportant un seul neurone et donnant le résultat de tous les calculs internes. Il existe entre ces deux couches une couche non visible de l'extérieur (hidden) appelée couche « cachée », qui est, en fait, une boîte noire. Là où tous les calculs intermédiaires et transformations s'effectuent.

Depuis 1943, des modèles beaucoup plus détaillés et réalistes pour des systèmes plus vastes du cerveau ont été développés, ce qui a amené à la nouvelle discipline, les neurosciences algorithmiques. Ces réseaux de neurones ont aussi la capacité à faire du calcul distribué, à tolérer du bruit dans les entrées et à apprendre [12]. Enfin, il est à noter que le réseau neuronal est privilégié pour traiter des non linéarités, et de la complexité en travaillant sur des données caractérisées par l'incomplétude et l'imprécision. De même, les réseaux de neurones sont utilisés pour **la segmentation** et **la classification** (Collins & Clark, 1993).

### I.6.3. Calcul évolutif (Algorithmes génétique) :

De nombreux problèmes scientifiques peuvent être formulés comme des problèmes d'optimisation. Parmi les algorithmes évolutionnaire d'optimisation pour résoudre de tels problèmes, un groupe intéressant simulant des phénomènes biologique tels que la population, la sélection naturelle, l'héritage génétique, mutation et les lois de survies énoncés par Darwin, est celle des techniques d'optimisation de l'évolution [19]. Ici nous donnons un aperçu sur l'une de ces méthodes, la méthode la plus fondamentale et la plus connue, celle des algorithmes génétiques.

C'est en 1860 que Charles Darwin publie son livre intitulé *L'origine des espèces au moyen de la sélection naturelle ou la lutte pour l'existence dans la nature*. Dans ce livre, Darwin rejete l'existence «de systèmes naturels figés», déjà adaptés pour toujours à toutes les conditions extérieures, et expose sa théorie de l'évolution des espèces : sous l'influence des contraintes extérieures, les êtres vivants se sont graduellement adaptés à leur milieu naturel au travers le processus de reproductions.

Au début des années 1970, John Holland, l'un des fondateurs du calcul évolutif, a introduit le

concept des algorithmes génétiques (Hollande, 1975). Son but était de rendre les ordinateurs capables de faire ce que la nature fait.

Selon cette méthode, des milliers de solutions (génotypes) plus ou moins bonnes sont créées au hasard, puis, sont soumises à un procédé d'évaluation de la pertinence de la solution mimant l'évolution des espèces.

### I.6.3.1. Les chromosomes :

Tous les organismes vivants sont constitués de cellules telles que les neurones, comme décrit précédemment. Les chromosomes sont des structures dans les noyaux cellulaires qui transmettent l'information génétique.

Chaque représentant d'une espèce donnée à un nombre caractéristique de chromosomes. Les humains ont normalement 46, apparaissant comme 23 paires homologues chez les femelles, et 22 paires homologues et d'une paire non identique chez le mâle. Une de chaque paire est dérivée du père, une autre de la mère. Une esquisse de trois paires de chromosomes humains apparaît à la figure ci-dessous.



Figure 1.10 illustrant des chromosomes

Les modèles individuels, dans les systèmes de calcul de l'évolution sont essentiellement analogues aux chromosomes dans les systèmes biologiques. En fait, le terme chromosome est couramment utilisé dans la plupart des algorithmes génétiques et des systèmes de programmation évolutionnaires. En génétique, la collecte des chromosomes requis pour spécifier complètement un organisme est appelé *le génotype*. Dans le calcul évolutif, la collecte des motifs nécessaires pour spécifier complètement un système est connu en tant que structure.

Dans le monde biologique, les chromosomes sont constitués de gènes, dont chacun est identifié par son emplacement et sa fonction. En d'autres termes, les gènes sont des segments de chromosomes spécifiques associés à des fonctions spécifiques. Les valeurs individuelles qu'un gène peut prendre sont appelés allèles; une valeur de allèle, peut-être la couleur des cheveux d'une personne. Dans les chromosomes artificiels de systèmes de calcul évolutif, les motifs de chromosomes sont composés de paramètres ou caractéristiques, qui peuvent varier sur une plage déterminée de valeurs. Un paramètre ou une fonction donnée occupe un emplacement fixe dans le chromosome artificiel. Le chromosome est donc codé pour représenter un ensemble de paramètres [49].

### **I.6.3.2. La reproduction dans un chromosome biologique et l'artificiel :**

La reproduction dans les chromosomes biologiques se reproduit lors de la division cellulaire. Dans le calcul évolutionnaire, la duplication (division cellulaire) des chromosomes est analogue à ce qui se produit au cours de la division cellulaire biologique, généralement appelée «reproduction». En outre, la synthèse de nouveaux chromosomes de deux «parents» est appelé **croisement**, ou recombinaison, dans le calcul évolutionnaire. En outre, au cours du croisement, un certain nombre de bits ou des valeurs réelles peuvent être échangées entre deux parents chromosomes artificiels [25].

### **I.6.3.3. L'algorithme génétique :**

L'algorithme génétique (AG) est un algorithme de recherche basé sur les mécanismes de la sélection naturelle et de la génétique, c'est aussi un algorithme stochastique qui imite le processus naturel de l'évolution biologique. Il suit le principe du darwinisme, qui repose sur la croyance fondamentale de la «survie du plus fort» dans le processus de la sélection naturelle des espèces. Ils simulent ce mécanisme évolutif en utilisant l'hérédité et la mutation [12] utilisé pour fournir des solutions utiles pour les problèmes d'optimisation [3].

En particulier, cet algorithme est un algorithme méta heuristique. Contrairement à des techniques d'optimisation, les algorithmes méta heuristiques ne peuvent pas garantir une solution optimale ou même une solution quasi-optimale, mais les métaheuristiques performant beaucoup plus rapidement que les techniques d'optimisation traditionnelles, et peuvent souvent fournir une solution acceptable. Un avantage particulier de l'algorithme génétique est la flexibilité dans la modélisation du problème, ce qui permet une grande linéarité, contrairement aux techniques d'optimisation, qui sont généralement limités.

### **I.6.3.4. Critères de terminaison classiques utilisés dans les algorithmes génétiques :**

L'algorithme génétique représente un processus itératif, dont chaque itération est appelée une génération, il maintient une liste de bonnes solutions appelée *la population*, cet ensemble de population est créée aléatoirement, pour un problème pour lequel la solution est inconnue. Ce problème est décrit dans un algorithme génétique, par une fonction de remise en forme appropriée et le chromosome. Le but de la fonction de remise en forme est d'évaluer l'opportunité de chaque solution. Ceci est important dans le choix des solutions qui doivent être conservés ou utilisés pour générer de nouvelles solutions.

De nouvelles solutions à côté de la population actuelle sont comparés les unes aux autres, pour sélectionner les solutions les plus appropriées pour la nouvelle population. Les nouvelles solutions devraient idéalement préserver les bonnes caractéristiques des solutions précédentes. En conséquence, après un certain nombre de reproductions successives, les chromosomes de moins bonne forme disparaissent d'après le processus de sélection inspiré de Darwin. Il convient de noter que le processus de sélection est principalement chargé d'assurer la survie des individus les mieux adaptées [35]. Autrement dit, garder et utiliser les meilleurs individus de la population qui ont une meilleure chance (les plus forts) de transmettre une partie de leur héritage génétique (les meilleurs gènes) pour créer des

descendants pour la prochaine génération [12]. Les itérations se poursuivent jusqu'à ce que l'un des critères de terminaison, par exemple un nombre maximal d'itérations est atteint. La dernière génération comporte l'information génétique qui correspond à la meilleure solution au problème.

#### **I.6.3.5. Le codage :**

Une solution dans l'espace de solution est représentée par un codage des variables de décision du problème, qui est habituellement effectuée dans un tableau de variables binaires ou réelles. Par analogie avec la génétique, la structure de ce codage est appelée le chromosome, tandis que chaque solution particulière (par exemple, un membre de la population) est généralement appelé un individu. Un élément d'un chromosome est appelé un gène, alors que la valeur qui est représentée par un gène est connue sous le nom allèle.

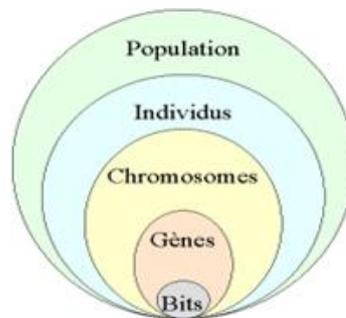


Figure 1.11 les cinq niveaux d'organisation d'un algorithme génétique

On utilise un codage des informations : on représente toutes les caractéristiques d'une solution par un ensemble de gènes, c'est-à-dire un chromosome, sous un certain codage (binaire, réel, code de Gray, ...etc.), valeurs qu'on concatène pour obtenir une chaîne de caractères qui est spécifique à une solution bien particulière. Chaque paramètre d'une solution est assimilé à un gène, toutes les valeurs qu'il peut prendre sont les allèles de ce gène, on doit trouver une manière de coder chaque allèle différent de façon unique.

#### **I.6.3.6. Le croisement ou Cross over :**

L'opérateur le plus important en termes de robustesse de l'algorithme. La figure montre l'opérateur de croisement d'un point, qui combine les informations des deux parents. Ils sont alignés, puis à la fois coupés à un point de croisement choisi au hasard, et les queues sont échangés successivement. Il combine deux individus pour créer deux descendants, qui prennent les deux parties de leur chromosome de l'un des deux parents. Au lieu d'un seul point de croisement, deux ou plusieurs points de croisement aléatoire peuvent être utilisés pour recombiner l'information génétique des parents.

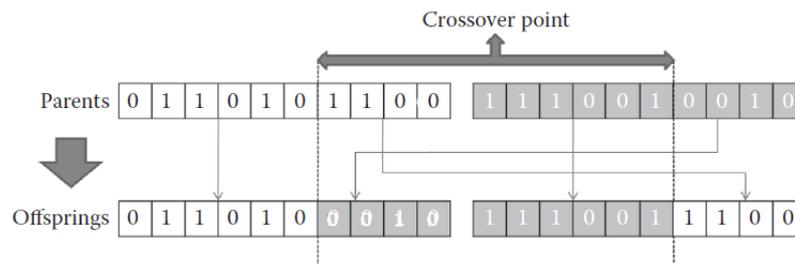


Figure 1.12 montrant le processus de croisement

### I.6.3.7. La mutation :

Elle utilise un individu et modifie un ou plusieurs gènes dans l'individu sélectionné pour créer un nouveau au hasard. Le cross over fait en sorte que les bonnes caractéristiques sont portées à la prochaine génération, tandis que la mutation est nécessaire de créer une grande diversité parmi les chromosomes [12].

Après que l'information génétique des parents est recombiniée en utilisant le croisement, la mutation est appliquée à chaque individu de la nouvelle génération. Chaque bit de la progéniture est inversé (muté). L'opération de mutation est importante pour restaurer les informations perdues et de produire une meilleure efficacité de l'algorithme génétique.

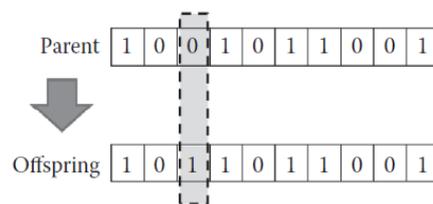


Figure 1.13 montrant l'opération de mutation

Les caractéristiques ou variable à déterminer sont alors utilisées dans des séquences de gènes qui seront combinées avec d'autres gènes pour former des chromosomes et par après des individus.

Chaque solution est associées à un individu, et cet individu est évalué et classifié selon sa ressemblance avec la meilleure, mais encore inconnue, solution au problème.

L'algorithme génétique de base comporte trois opérations simples qui ne sont pas plu compliquées que de opérations algébriques :

- **sélection** : copier les individus selon la valeur de leur fonction objectif ; alors les individus qui ont des valeurs plus élevées contribueront à la génération de nouvelles populations.
- **reproduction** : processus où de nouveaux individus sont formés à partir de parents en effectuant un croisement entre deux parents.

- **mutation** : processus aléatoire où un bit change de valeur.

Les algorithmes génétiques seuls ne sont pas très efficaces dans la résolution d'un problème. Ils apportent cependant assez rapidement une solution acceptable. Néanmoins, il est possible de l'améliorer assez efficacement en le combinant avec un algorithme déterministe.

### **I.7. Implémentation et les synergies de l'intelligence computationnelle :**

Ce qui est nécessaire est une unification des différentes méthodes de l'intelligence computationnelle, par conséquent, une approche combinée avec ses techniques et leur mise en œuvre est d'une importance pour une performance globale, et pour le coût du calcul et la commodité d'application. La combinaison synergique de ces méthodologies peut fournir de meilleurs modèles informatiques ou des algorithmes plus efficaces qui viendront compléter les limites de toute méthode unique individuelle. Cette combinaison se fut appelée par de nombreux chercheurs, un système intelligent hybride. Zadeh (1994) pense que les systèmes intelligents hybrides sont certainement la voie de l'avenir [4] [29].

Les différentes synergies des méthodes de l'intelligence computationnelle sont comme suite [29] :

- La logique floue avec les réseaux de neurones (système neuro-flou)
- Le calcul évolutionnaire avec les réseaux de neurones.
- Le calcul évolutionnaire avec la logique floue (synergisme évolutionnaire flou).
- L'hybride du calcul évolutionnaire, la logique floue et les réseaux de neurones (hybride de systèmes neuro-flou utilisant l'algorithme génétique).

Il ne nous ait pas caché qu'il existe d'autres combinaisons synergiques au-delà de celle-ci. Et comme nous pouvons le noter, que les hybrides des techniques ou méthodes de l'intelligence computationnelle sont généralement et quasiment construites sur une base de calculs évolutionnaires (algorithmes génétiques) vu que ces derniers ont la propriété d'optimisation et d'adaptation d'un comportement pour un système.

### **I.8. Conclusion :**

Dans ce chapitre nous avons fournis des informations de base à partir desquelles on peut se renseigner sur l'intelligence computationnelle, et sa mise en œuvre ou son implémentation. Nous avons aussi introduit des définitions, ainsi que ses méthodes ou techniques les plus pondérantes.

Les méthodes étudiées en détail dans les applications médicales sont conçues pour aborder des problèmes médicaux vu que ces derniers sont de nature complexe et vague. Les Réseaux de Neurones Artificiels imitent le système nerveux de l'humain en simulant un réseau de neurones artificiels, qui agit de manière similaire aux neurones biologiques en termes de **prise de décision**. D'autre part, l'algorithme génétique qui est basé sur le concept de l'évolution biologique est le sujet le plus recherché dans l'affaire Calcul Evolutionnaire, qui est un outil pour l'optimisation. Le langage naturel, la modélisation du raisonnement humain même en cas de manque d'information, en donnant des définitions de termes vagues et permettant la construction d'une base de règles, sont les concepts de la logique floue et les systèmes flous.

Ayant compris la base biologique pour ces méthodes, nous sommes en mesure de mieux conceptualiser et comprendre comment ces systèmes fonctionnent. Les techniques de l'IC sont souvent conçus pour imiter un ou plusieurs aspects de l'intelligence biologique, et fournissent de bonne approches lorsqu'on traite des systèmes complexes dans un environnement qui change, et l'hybridation des différentes techniques est une façon de résoudre un problème qui est très difficile pour être résolu par d'autres méthodes hors que celle étudiées dans ce mémoire, et elle permet de compléter les limites de toute méthode individuelle.

## II. Introduction :

Le traitement d'images voit ses débuts dans les années 1920 dans la transmission d'image par câble sous-marin, mais ne connaît le véritable essor que dans les années 1960 avec le développement des ordinateurs pour travailler sur des images. Au départ, les techniques de traitement d'images sont des méthodes de restauration, d'amélioration et de compression d'images. Puis se développent avec les progrès de l'informatique, et avec la redécouverte de la transformée de fourrier rapide, formalisant ainsi des techniques de détection de contours d'une manière précise, et de nombreux autres traitements dans les domaines aussi variés que le médical, la télévision, l'imagerie satellitaire, et le multimédia. C'est dans les années 2000 que l'image numérique et par conséquent le traitement d'images devient omniprésent. Que cela soit sur internet, à la télévision, sur les téléphones, ou dans le domaine médical, l'image est partout. Aujourd'hui il ne s'agit plus uniquement de traiter les images pour les améliorer, mais aussi de les comprendre et de les interpréter. C'est dans ce contexte que la reconnaissance d'objets dans les images devient un sujet de recherche important. Et pour reconnaître des objets, il faut souvent les segmenter, c'est-à-dire séparer les objets d'intérêt du fond de l'image.

Alors comment déterminer ces derniers ? C'est tout le problème de la segmentation d'images qui est un problème mal posé.

Ce qui représente au mieux les objets peut être une couleur particulière, ou une forme précise. Mais est-ce suffisant ? Pour extraire un objet d'une scène, nous devons connaître les propriétés de cet objet. Alors comment reproduire cela avec un ordinateur qui ne dispose que de pixels ?

*« Le seul moyen de faire une méthode instructive et naturelle, est de mettre ensemble les choses qui se ressemblent et de séparer celles qui diffèrent les unes des autres. »*

M. Georges Buffon, Histoire naturelle, 1749

Nous présenterons dans ce chapitre tout d'abord ce que c'est l'image, ainsi que quelques notions et caractéristiques la concernant, puis on passera à la segmentation et à la classification, leurs méthodes, techniques, leurs grandes approches et on détaillera à la fin une des grandes approches en étudiant et analysant deux des algorithmes de segmentation.

### II.1. Généralités:

**II.1.1. Définition de l'image :** L'image se définirait comme une représentation ou une reproduction de quelque chose, ou d'une scène, d'un objet situé dans l'espace tridimensionnel.

Mathématiquement, elle peut être décrite sous la forme d'une fonction à deux dimensions d'intensité  $I(x, y)$  tel que :  $x$  et  $y$  sont des coordonnées spatiales d'un point de l'image à 2D, et  $I$  est une fonction d'intensité lumineuse (niveau de gris et de couleur).

L'image  $I(x, y)$  est représentée par une matrice de  $m \times n$  éléments, sachant qu'un pixel correspond à un élément  $I(x, y)$  de cette matrice.

## II.1.2. Les types d'image :

**II.1.2.1. Les images Matricielles:** Les images matricielles (ou image en mode point, en anglais « bitmap ») sont celles que nous utilisons généralement pour restituer des photos numériques. Elles reposent sur une grille de plusieurs pixels formant une image avec une définition bien précise. Lorsqu'on les agrandi trop, on perd de la qualité.

**II.1.2.2. Les images Vectorielles:** Ce sont des images dont la particularité est que chaque forme qui la compose est décrite mathématiquement à partir de points et de tangentes. Elles ne peuvent pas décrire une image trop complexe comme une photographie, mais sont tout à fait adaptées au rendu typographiques, aux logos et autres formes composées de tracés simples.

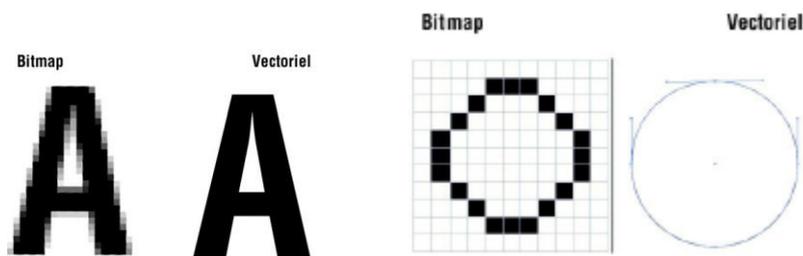


Figure 2.1 les types d'images (vectorielles et matricielle)

D'autres types d'image sont distingués :

- L'image cohérente : formée de la sommation en amplitude complexe des rayonnements issus des objets constituant un même pixel.
- L'image incohérente : obtenue avec des sources de lumière naturelle ou de rayonnements incohérents (c'est le cas d'image vidéo ainsi que la plupart des photos satellitaires ou médicale utilisée dans ce travail).

Ces rayonnements qu'ils soient en phase ou en opposition de phase créeront un pixel clair ou sombre.

## II.1.3. Numérisation de l'image :

Le passage à une représentation numérique se fait en réalisant une discrétisation des coordonnées spatiales dans les deux dimensions de l'image (donnant la définition de l'image), échantillonnage, et une discrétisation de l'amplitude (ou quantification des niveaux de gris), codé numériquement avec une certaine précision (nombres codés sur un certain nombre de bits). L'image est donc constituée par un ensemble régulier d'éléments appelés « pixels ».

C'est cette forme numérique qui permet une exploitation ultérieure par des outils logiciels sur ordinateur.

#### **II.1.4. Caractéristiques de l'image numérique :**

Les images numériques sont de plus en plus présentes dans notre quotidien : télévision numérique terrestre, photographie, imagerie médicale. Une image numérique est une image dont le support est stocké sous forme binaire dans un fichier informatique, c'est une image discrète.

#### **II.1.5. Attributs de l'image:**

##### **II.1.5.1. Le pixel:**

C'est le point d'intersection entre une ligne verticale et une ligne horizontale. Le pixel est le plus petit point de l'image, Il provient de l'expression « *picture element* » élément d'image, à chaque pixel on associe un niveau de gris et une étiquette.

##### **II.1.5.2. Image noir et blanc :**

Le noir et blanc est le plus simple. Le contenu de chaque case de la matrice est soit un 0 (noir) soit 1 (blanc).

##### **II.1.5.3. Image couleur :**

Principe : La couleur d'un pixel est obtenue, comme le ferait un peintre, par le mélange de couleurs fondamentales. Nous allons décrire un des principes les plus couramment utilisé qui est celui de la synthèse additive.

Codage RVB : Le principe consiste à mélanger les 3 couleurs : rouge, vert et bleu (noté RVB). A l'aide de ces 3 couleurs, on obtient toute une palette de nuances allant du noir au blanc. A chaque couleur est associé un octet (donc 256 niveaux de luminosité) de chacune des couleurs fondamentales.

##### **II.1.5.4. Niveaux de gris :**

Le niveau de gris représente la luminosité d'un pixel. Le codage dit en niveaux de gris permet d'obtenir plus de nuances que le simple noir et blanc. Il offre des possibilités supplémentaires pour coder le niveau de l'intensité lumineuse. La couleur est codée souvent sur un octet soit 8 bits ce qui offre la possibilité d'obtenir 256 niveau de gris (0 pour le noir et 255 pour le blanc).

##### **II.1.5.5. L'histogramme :**

Un histogramme est un graphique statistique permettant de représenter la distribution des intensités des pixels d'une image, c'est-à-dire le nombre de pixels pour chaque intensité lumineuse. Par convention un histogramme représente le niveau d'intensité en abscisse en allant du plus foncé (à gauche) au plus clair (à droite).

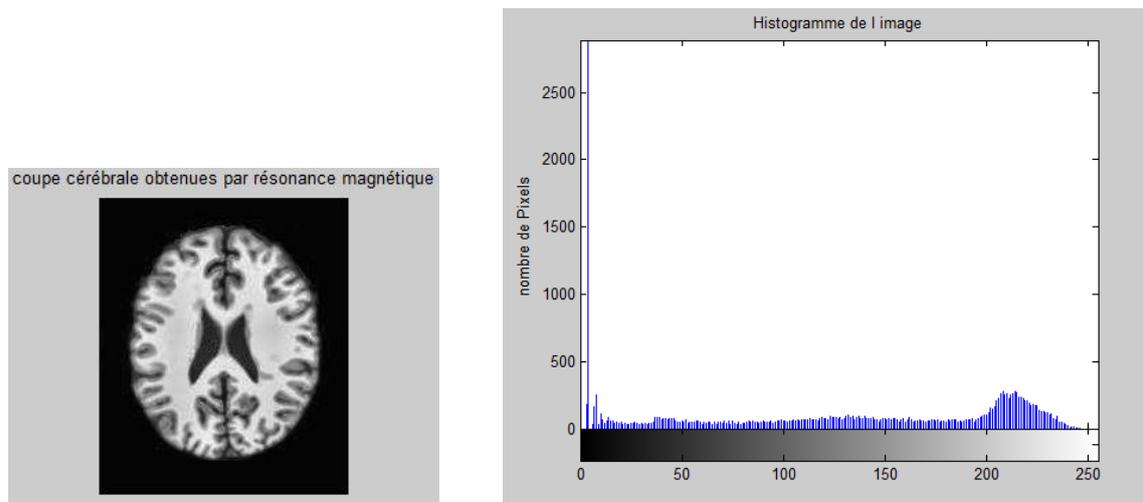


Figure 2.2 : une image cérébrale avec son histogramme représentant la répartition des pixels en fonction de leur luminosité (niveau de gris)

#### II.1.5.6. Résolution d'une image :

La résolution détermine le nombre de points par unité de surface, exprimé en *pixels par pouce*; un pouce représentant 2.54 cm. La résolution permet ainsi d'établir le rapport entre le nombre de pixels d'une image et la taille réelle de sa représentation sur un support physique. La résolution de l'écran est exprimée sous la forme d'une multiplication entre le nombre de pixels horizontaux et le nombre de pixels verticaux [47].

Dans le domaine informatique et des images numériques, la résolution sert à mesurer la *qualité* d'une image. Plus la résolution est haute, plus la qualité est meilleure.

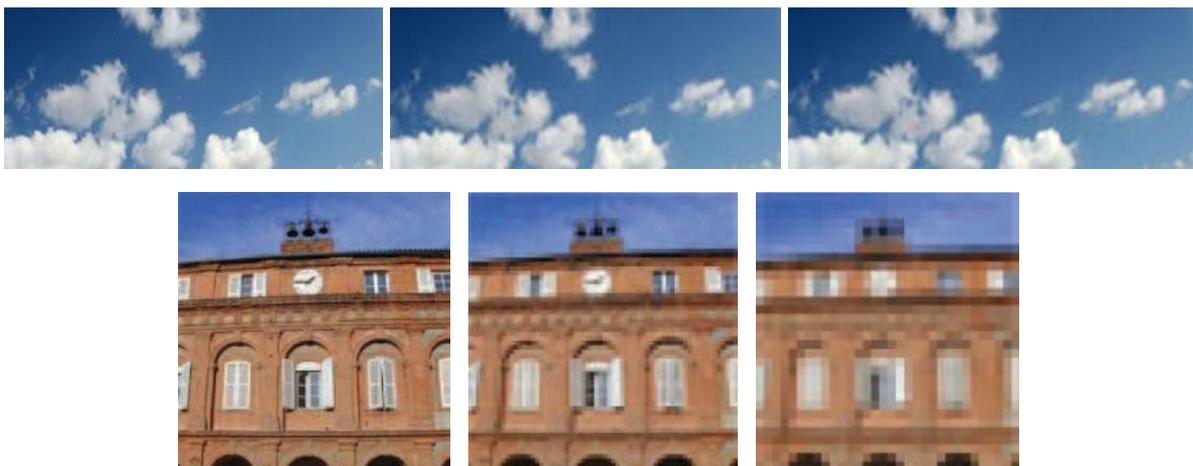


Figure 2.3 montrant la résolution d'image

### II.1.5.7. Luminance ou brillance d'une image :

Elle est définie comme la moyenne de tous les pixels de l'image. Pour augmenter la luminance, il suffit de décaler l'histogramme :  $I'(i, j) = I(i, j) + b$

La luminosité des points de l'image est définie comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface.

Dans les deux images suivantes, seule la luminance est différente :

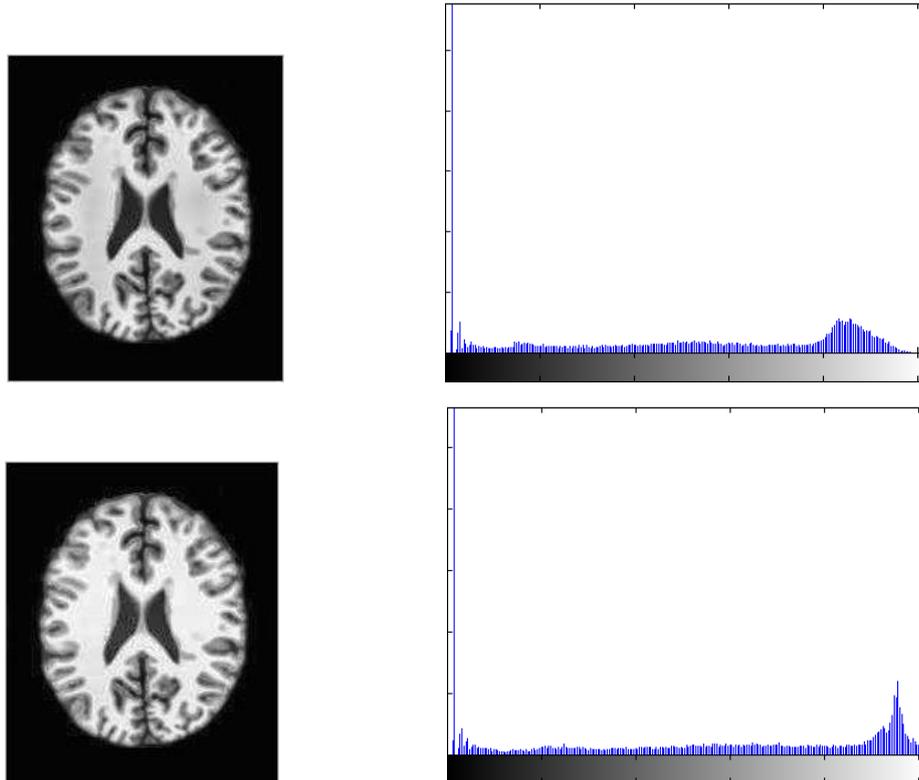


Figure 2.4 une image originale en haut avec son histogramme, et en bas la même image réglant sa luminosité à 24%

### II.1.5.8. Le contraste :

Le contraste caractérise la répartition lumineuse d'une image, quantifie la différence de luminosité entre les régions claires et sombres d'une image.

Si  $L_1$ ,  $L_2$  sont les degrés de luminosité respectivement de deux zones voisines  $A_1$ ,  $A_2$  d'une image, le contraste  $C$  est défini par le rapport :

$$C = \frac{(L_1 - L_2)}{(L_1 + L_2)}$$

### II.1.5.9. Le bruit :

Un système d'enregistrement d'images ne restitue pas l'image de manière parfaite. En effet des informations parasites s'ajoutent de manière aléatoire aux détails de la scène d'origine, c'est ce qu'on appelle : bruit.

### II.1.5.10. Le rehaussement :

Un opérateur de rehaussement vise à remplacer le pixel central par la somme des différences avec ses voisins.

## II.2. Traitement de l'image :

- amélioration des images pour l'interprétation par un observateur humain
- traitement de scènes en temps réel pour la perception par des automates

Traitement d'images envisagé en trois phases :

1. **Acquisition** : capture et acquisition des données physiques sous forme d'une image qui peuvent correspondre simplement à des intensités lumineuses d'une scène, discrétisation et numérisation de l'image réelle.
2. **Prétraitement** : permet une meilleure visualisation et qualité de l'image avec la facilité des traitements ultérieurs, il peut s'agir de la réduction du bruit par filtrage, ou rehaussement du contraste de l'image.
3. **Segmentation** : crée une partition de l'image en régions et détecter leurs frontières.

Après ceci, des étapes d'analyse appelées post-traitement qui servent d'amélioration et correction de l'image acquise, et d'interprétation se manifestent. Les caractéristique de l'image sous forme d'un vecteur d'attributs sont extraient, la classification des résultats de la segmentation en régions s'effectue. Et pour finir une dernière étape d'interprétation qui consiste à étiqueter les régions détectées.

## II.3. Définition de la segmentation d'image :

La segmentation d'image est l'une des tâches les plus difficiles dans l'analyse d'image. Cette opération consiste à diviser ou partitionner l'image en différentes régions homogènes ayant des caractéristiques similaires et de trouver ses contours.

L'intérêt de ces régions est de pouvoir être manipulées ensuite via des traitements de haut niveau pour extraire des caractéristiques de forme, de position, de taille, etc.

Plus formellement, [40] la segmentation peut être défini comme une partition de l'image  $I$  en sous-ensembles disjoints non vide  $R_i$  pour  $i=1,2,\dots,M$  appelées régions tels que :

$$I = \bigcup_{i=1}^n R_i \text{ et } R_i \cap R_j = \emptyset \text{ pour tout } i \neq j$$

Ces régions contenant des pixels connexes au sens d'un prédicat. Cet ensemble de pixels formant une région sont topologiquement connexes et ayant des attributs similaires : niveaux de gris, couleur...etc.

Mathématiquement, la segmentation est définie par Zucker de la manière suivante [Zucker, 1976] : Segmenter une image  $I$  en  $N$  régions, revient à la partitionner en  $n$  sous-ensembles  $R_1, R_2, \dots, R_n$  tels que et surtout avantageuse :

1.  $I = \bigcup_i R_i$
2.  $R_i$  est constituée de pixels connexes pour tout  $i$ .
3.  $P(R_i) = \text{Vrai}$  pour tout  $i$ .
4.  $P(R_i \cup R_j) = \text{Faux}$  pour tout  $i \neq j$ ,  $R_i$  et  $R_j$  étant adjacentes dans  $I$ .
  - la première condition indique que chaque pixel de l'image doit appartenir à une région  $R_i$  et l'union de toutes les régions forme l'image entière.
  - la deuxième condition est relative à la structure des régions, elle définit une région comme un ensemble de pixels qui doivent être connexes.
  - la troisième condition exprime que chaque région doit respecter un prédicat d'uniformité.
  - la dernière condition implique la non réalisation de ce même prédicat pour la réunion de deux régions adjacentes.

#### **Définitions :**

*Prédicat* :  $P$  Proposition logique : 1 si la propriété est VRAIE, 0 si elle est fausse.

*Prédicat d'homogénéité ou prédicat d'uniformité* : mesure l'uniformité d'une région  $R_i$ .

Exemple : 1 si variance d'intensité < seuil

0 sinon.

#### **II.4. Objectifs de la segmentation [41] :**

- L'extraction d'éléments et d'informations qualitatives de l'image.
- Fournir des régions homogènes
- Localiser les contours de région.
- Fournir une description de haut niveau : représentation par un graphe dont les nœuds sont des régions, chaque région est connectée à ses voisines et chaque région porte une étiquette qui donne des informations comme la taille, la couleur, la forme,...
- Réduire le bruit.

## **II.5. Différentes approches :**

Après de nombreuses années passées à rechercher la méthode optimale, les chercheurs ont compris que la segmentation idéale n'existait pas.

Etant donnée une image, il existe toujours plusieurs segmentations possibles. Une bonne méthode de segmentation sera donc celle qui permettra d'arriver à une bonne interprétation. Elle devra donc avoir simplifié l'image sans pour autant en avoir trop réduit le contenu.

Dans la littérature, on trouve une multitude de méthodes de segmentation, mais aucune ne permet d'obtenir des résultats satisfaisants pour toutes les images. Le choix de la méthode dépend souvent des connaissances *a priori* sur l'image.

### **II.5.1. Approche contours :**

Cette procédure permet de réduire considérablement la quantité d'informations contenue dans l'image à l'état brut. Son principe consiste à identifier les changements entre les régions. Elle se caractérise par le fait qu'elle ne prend en compte que des informations sur le contour des objets.

Cette approche détecte les zones de fortes discontinuités de l'image, dont l'élément de contour qui se situe entre les pixels, appartient à la frontière des objets ayant des niveaux de gris différents. Les contours constituent des indices riches, pour toute interprétation ultérieure de l'image, puisque c'est les frontières entre les objets qui nous permettent de définir l'objet [8].

Cette technique purement locale est en général trop limitée pour traiter des images bruitées et complexes. Ce qui rends la détection de contour difficile, vu le bruit important présent dans l'image (bruit d'échantillonnage, bruit du capteur...).

Considérer uniquement les contours pour extraire des objets d'intérêt n'est pas toujours satisfaisant.

### **II.5.2. Approche région [38] :**

Une approche duale de l'approche contours pour la décomposition d'une image en ses formes élémentaires, c'est à dire en un ensemble de régions connexes les plus homogènes possible est, l'approche région. Cette approche cherche à regrouper les pixels partageant des propriétés communes en régions homogènes, de cette manière elle se caractérise par la mesure d'uniformité ou d'homogénéité des régions construites dans l'image, des régions possédant des attributs similaires, tels que les niveaux de gris, couleur, texture. L'union des régions obtenues doit redonner l'image initiale.

## II.6. La classification :

La classification est l'une des procédures les plus utilisées en analyse des données, elle permet de partitionner un ensemble de données multidimensionnelles en un ensemble de classes disjointes. Cette technique de segmentation par classification de pixels, consiste à attribuer à des pixels dans l'image, une étiquette indiquant la classe à laquelle ils appartiennent. Les pixels regroupés dans la même classe doivent être les plus similaires que possible (selon les niveaux de gris), donc des classes générées homogènes. Sachant que les pixels de deux classes distinctes ont des attributs ou des caractéristiques très différentes. Ces deux critères jugent la qualité de la classification [24]. De cette manière toute l'image est partitionnée en un nombre limité de classes correspondant aux grands éléments structuraux de l'image [37].

D'un point de vue général, les méthodes de classification ont pour but de regrouper les éléments d'un ensemble  $X = \{x_1, \dots, x_n, \dots, x_N\}$  en un nombre  $C$ , optimal de classes selon leurs ressemblances [43]

Cette affectation selon Bezdek [15] peut être effectuée on se basant sur des régions dont on connaît les classes d'appartenance *a priori*, alors, on parle de classification supervisée, ou non, dans ce cas on parle de classification non-supervisée (clustering). Ces procédures permettant d'associer un objet à une classe, seront discutées dans la suite du mémoire.

### II.6.1. La classification supervisée :

L'objectif est d'apprendre un modèle de classification à partir d'une base d'apprentissage étiquetée par un superviseur. Ce sont des méthodes dans lesquelles les classes des objets sont connues *a priori* avant d'effectuer l'opération d'identification des éléments de l'image.

### II.6.2. La classification non supervisée :

La classification non supervisée (clustering), s'intéresse au processus d'extraction ou de partitionnement d'une organisation, c'est à dire à la manière de classer les données observées au sein de structures dans lesquelles elles se regroupent "naturellement". Dans ce type de classification, le nombre de classes inconnues, *a priori*, est déduit directement des données. L'appartenance des observations à des populations est inconnue, elle ne nécessite pas une base d'apprentissage ou un étiquetage par une intervention extérieure (un expert humain). Son objectif est de regrouper dans le même *cluster* les observations jugées similaires (homogénéité intra-classe) et de placer les observations jugées dissimilaires dans des *clusters* distincts (hétérogénéité inter-classe) [35].

Il existe une très large famille de méthodes dédiées à la classification non supervisée et qui ont été développées. Dans ce mémoire, nous n'en présentons que trois. L'algorithme des k-moyennes (k-means) mis au point par McQueen en 1967, il doit sa popularité à sa simplicité et sa capacité de traiter de larges ensembles de données, et est basé sur la distance entre objets, et sa version

floue : les C-moyennes floues (fuzzy C-means "FCM"), un regroupement basé sur des appartenances floues. Le troisième est à découvrir dans un autre chapitre.

### **II.7. Les étapes d'une classification :**

1. sélection et préparation des données à classer.
2. Calcul des similarités entre les n individus à partir des données initiales.
3. Choix d'un algorithme de classification et exécution.
4. L'interprétation des résultats :
  - évaluation de la qualité de la classification.
  - description des classes obtenues.

### **II.8. Le regroupement (clustering) :**

Comme nous l'avons dit dans ce qui précède, le regroupement est une méthode de classification non supervisée, qui permet d'organiser ou de regrouper dans le même cluster des objets dans des groupes ou classes d'objet plus homogènes. Ces objets sont similaires entre eux au sein d'un même groupe, et dissimilaires pour les objets appartenant à d'autres groupes différents [12].

Dans ce type de méthodes les classes seront obtenues à l'aide d'algorithmes formalisés. On distingue aussi les méthodes de classification non hiérarchiques et les méthodes de classification hiérarchiques.

**II.8.1. Méthodes hiérarchiques.** Cette approche utilise la notion de distance, on considère qu'un élément appartient à une classe s'il est plus proche de cette classe que de toutes les autres.

**II.8.2. Méthodes non hiérarchiques.** Ce sont des méthodes qui produisent directement une partition en un nombre fixé de classes.

Les algorithmes de clustering utilisent une fonction de distance pour mesurer la similitude des points de données les uns avec les autres, et ensuite utiliser cette information pour les regrouper en un nombre fixe de grappes. L'objectif de ces algorithmes est de minimiser les distances entre les observations dans chaque groupe, tout en maximisant la distance d'observation en une grappe avec des observations dans un autre groupe.

### **II.9. Dissemblance et distance (*Similarité, dissimilarité*) :**

Comme nous l'avons dit sur la classification non supervisée (clustering), en l'absence de toute hypothèse concernant la distribution des données, le regroupement des observations en classes se fait sur des considérations géométriques : on regroupe des observations qui sont « proches » les

unes des autres dans l'espace de représentation (l'espace des variables). Cette première intuition montre la nécessité de définir une mesure de la proximité entre les observations. C'est pourquoi nous commençons par introduire les notions de similarité, de dissimilarité et de distance entre ces points ; deux individus sont d'autant plus similaires qu'ils sont proches au sens d'une mesure de dissimilarité.

**Définitions :** Afin de définir l'homogénéité d'un groupe d'observations, il est nécessaire de mesurer une ressemblance entre deux observations. On introduit ainsi les notions de dissimilarité et de similarité [10].

Une dissimilarité est une fonction  $d$  qui à tout couple  $(x_1, x_2)$  associe une valeur dans  $\mathbb{R}^+$ , et telle que :

$$d(x_1, x_2) = d(x_2, x_1) \geq 0 \quad (2.1)$$

$$d(x_1, x_2) = 0 \Rightarrow x_1 = x_2 \quad (2.2)$$

Un indice de dissemblance est une fonction  $d$  définie par [16]:

$$d: E \times E \rightarrow \mathbb{R}^+ \quad (x, y) \rightarrow d(x, y) \quad (2.3)$$

Tel que :

$$d(x, y) = d(y, x) \quad \forall x, y \in E. \quad (2.4)$$

$$d(x, x) = 0 \quad \forall x \in E. \quad (2.5)$$

La distance Euclidienne est un indice de dissemblance particulier qui satisfait la propriété d'inégalité triangulaire :

$$d(x, y) \leq d(x, z) + d(z, y) \quad \forall x, y, z \in E \quad (2.6)$$

L'ultramétrie remplace la condition précédente par la condition suivante :

$$d(x, y) \leq \sup(d(x, z); d(z, y)) \quad (2.7)$$

Une distance entre un individu et un groupe, et par la suite une distance entre deux groupes est naturellement inversement liée à l'appartenance de cet individu au groupe. On doit donc définir une stratégie de regroupements des éléments, c'est-à-dire se fixer des règles de calcul des distances entre groupes disjoints d'individus, appelées « critères d'agrégation ». Cette distance entre les classes pourra en général se calculer directement à partir des distances des différents éléments impliqués dans le regroupement.

Si  $x, y, z$  sont trois objets, et si les objets  $x$  et  $y$  sont regroupés en un seul élément noté  $h$ , on peut définir la distance de ce groupement à  $z$  par la plus petite distance des divers éléments de  $h$  à  $z$  soit :

$$\text{dist}(h, z) = \min(\text{dist}(x, z), \text{dist}(y, z)). \quad (2.8)$$

Ainsi, les distances permettent d'évaluer la similarité entre les objets. D'ailleurs, les termes « similarité » et « dissimilarité » sont équivalents, respectivement, à « Ressemblance » et « dissemblance ».

**II.10. Segmentation par la méthode des K-means :**

**II.10.1. L'algorithme k-moyennes (k-means) :**

Dans ce type d'algorithme, la classe est représentée par son centre de gravité noté  $v_i$  ses objets membres  $n_i$ . Les k moyennes traitent chaque observation dans les données comme un objet ayant un emplacement dans l'espace. Ils trouvent une partition dans laquelle des objets au sein de chaque groupe sont aussi proches les uns des autres que possible. Le centre de gravité pour chaque groupe est le point auquel la somme des distances de tous les objets de ce groupe est réduite au minimum.

L'idée principale de l'algorithme k-moyennes, est de définir un ensemble initial de points centraux de la grappe (C centres), et d'ajuster ces points centraux répétitivement afin de minimiser itérativement la distance totale des observations à leurs points centraux du cluster correspondants. Chaque point d'observation est affecté au centre le plus proche, après l'affectation de toutes les données, la moyenne de chaque groupe est calculée, et lorsque la somme ne peut plus être diminuée, l'algorithme s'arrête, et on obtient un ensemble de groupe qui est aussi compacts et bien séparés que possible, c'est la partition optimale [6]. La qualité d'un regroupement dépend donc de la mesure de similarité utilisée par la méthode et de son implémentation.

L'algorithme C-Means dans sa formulation originale cherche à minimiser une fonction de coût global définie par :

$$J(X, V) = \frac{1}{2} \sum_{i=1}^C \sum_{j=1}^N \|x_j - v_i\|^2 \tag{2.9}$$

Où :  $v_i$  est le centre du cluster  $i$ .

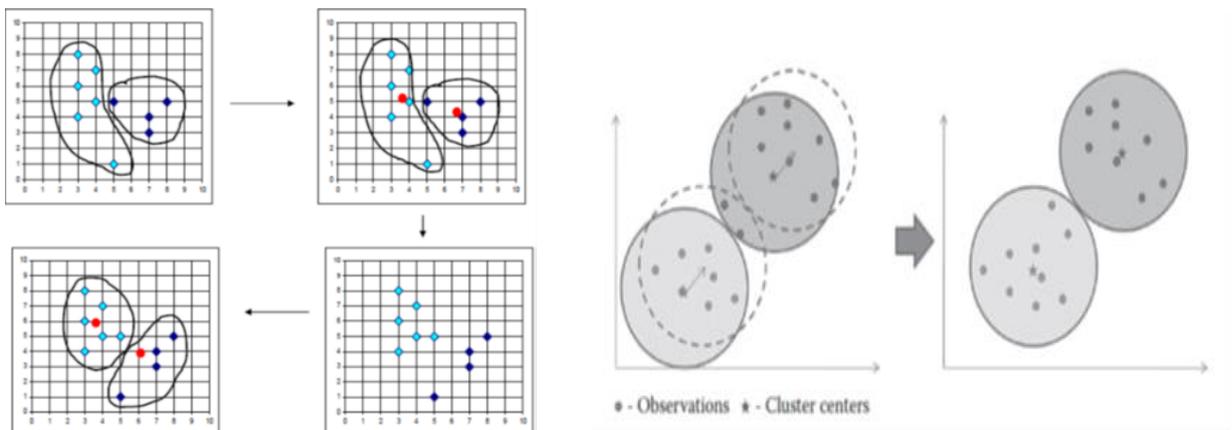


Figure 2.5 regroupement d'observation en clusters et le choix de leurs centres

La figure de droite illustre les changements qui peuvent survenir dans les points centraux des deux clusters, dans une itération. Comme il est indiqué, de nouveaux points centraux donneront une meilleure classification des observations. Quant à la figure de gauche, elle montre les étapes d'exécution de l'algorithme k-moyennes.

**Algorithme 1** Algorithme des K-means

**Etape 1 :** Choisir aléatoirement les  $C$  centres initiaux  $v_1, v_2, \dots, v_C$  à partir des points  $\{x_1, x_2, \dots, x_N\}$ . **Répéter**

**Etape 2 :** Assigner  $x_j, j=1, 2, \dots, N$  au cluster  $Z_i, i=1, 2, \dots, C$

Si

$$\|x_j - v_i\| \leq \|x_j - v_p\|, p = 1, 2, \dots, C \text{ avec } j \neq p$$

Choix aléatoire si conflit

**Etape 3 :** Calculer les nouveaux centres :  $v_i^* = \frac{1}{n_i} \sum_{x_j \in Z_j} x_j, i = 1, 2, \dots, C$   
 $n_i$  est le nombre d'éléments dans le cluster  $Z_i$

**Jusqu'à ce que**  $v_i^* = v_i, \forall i = 1, 2, \dots, C$ .

**II.11. Segmentation floue d'images par classification de pixels :**

Les méthodes de segmentation nettes considèrent que les régions constituent des sous-ensembles nets de l'ensemble des pixels constituant l'image. La reconstruction des régions s'effectuent en affectant chaque pixel à une seule région. Cette démarche présente des limites lorsque nous ne disposons pas de connaissance *a priori* sur l'affectation des pixels [2]. Elle s'appuie sur les concepts de la logique floue, où elle considère les pixels comme des sous-ensembles flous.

**II.11.1. Les C-means (CM) :**

L'algorithme des C-moyennes (C-means) est l'un des algorithmes de clustering les plus connus, il réalise un partitionnement automatique des pixels de l'image en  $C$  classes homogènes.

Soit  $E = \{x_1, x_2, \dots, x_n\}$  l'ensemble des échantillons de la base d'apprentissage.  $x_n$  est le  $n^{\text{ième}}$  vecteur d'attribut  $x$ . Les prototypes ou ensembles des centres de classes sont  $\{V_1, V_2, \dots, V_c\}$  où  $c$  dénote le nombre de classes.

Les algorithmes de type C-means minimisent tous une fonction objectif  $J$  (ou somme des distances intra-classes). Cette distance Euclidienne  $d$  est calculée entre le vecteur attribut des données et les prototypes de groupes. La fonction objective  $J$  est de la forme :

$$J = \sum_{i=1}^c \sum_{k=1}^n \mu_{ik} d^2(x_k, V_i) \quad (2.10)$$

Où :

- $V_i$  : Représente le centre de la classe  $i$ .
- $\mu_{ik}$  : Degré d'appartenance de  $x_k$  à la classe  $c_i$ .

### II.11.2. Méthodes floues de classification :

#### II.11.2.1. Les C-moyennes floues (FCM) :

Soit  $E$  un ensemble de vecteurs d'attributs,  $\{V_1, V_2, \dots, V_c\}$  les centres des différentes classes où  $c$  dénote le nombre de classes. Le degré d'appartenance d'un élément  $x_k$  à un groupe  $V_i$  est noté  $\mu_i(x_k)$ . Dans cette approche, un vecteur d'attribut donné peut appartenir à plusieurs groupes.

La structure de la matrice des degrés d'appartenance  $U = [\mu_{ik}(x_k)]$ :

$$\forall i, j, \mu(x_k) \in [0,1]$$

$$U = \begin{pmatrix} \mu_{11} & \mu_{12} & \cdots & \mu_{1n} \\ \mu_{21} & \mu_{22} & \cdots & \mu_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{c1} & \mu_{c2} & \cdots & \mu_{cn} \end{pmatrix} \quad (2.11)$$

Appelée aussi matrice de C-partition floue, elle est de dimension  $c \times n$  où  $c$  est le nombre de classes et  $n$  le nombre d'éléments à classer.

L'algorithme de classification non supervisé (FCM) développé dans les années 1970 [17] est une méthode de partitionnement d'ensemble basé sur la minimisation d'une fonction objectif ( $J_m$ ) :

$$J_m(U, V) = \sum_{i=1}^c \sum_{k=1}^n \mu_{ik}^m d^2(x_k, V_i) \quad (2.12)$$

Où :  $d = \|x_k - V_i\|$  est la norme Euclidienne et  $V_i$  représente le centre de la classe  $i$ .

Le paramètre  $m > 1$  contrôle le degré de flou. Plus  $m$  est grand, plus la partition est floue. En effet, Dunn a tout d'abord étendu  $J_1$  (pour  $m=2$ ) à  $J_2$  (pour  $m=2$ ). Bezdek lui a généralisé  $J_2$  à  $J_m$  ( $1 < m < \infty$ ).

**Algorithme 2** algorithme général d'exécution du FCM

**Etape 1 :**

Choisir le nombre de classes :  $c$ , fixer  $m$ ,  $1 < m < \infty$ , choisir  $\varepsilon$  pour le test d'arrêt. Initialiser ( $t=0$ ) la matrice de partition  $U^{t=0}$  des fonctions d'appartenance à des valeurs aléatoires ou bien en leur affectant comme valeur  $\frac{1}{c}$ .

choisir la mesure  $d_{ik} = \|x_i - c_k\|$ .

**Etape 2 :** calculer le vecteur C-means  $V_i$  des centres en utilisant l'équation de  $\mu_{ik}$ .

**Etape 3 :** mettre à jour  $U^t$  en utilisant :

$$\mu_{ik}^{t+1} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m-1}}}$$

**Etape 4 :** comparer  $J^{t+1}$  à  $J^t$  si  $|J_m^{t+1} - J_m^t| < \varepsilon$  alors arrêt sinon  $t = t+1$  et retourner à l'étape 2.

L'idée de base de la classification FCM est d'assigner à chaque vecteur  $x_k$  un degré d'appartenance  $\mu_{ik}$ , à chaque classe centrée en  $V_i$ . Elle utilise la propriété d'appartenance partielle des ensembles flous que verrons dans un autre chapitre. L'algorithme minimise une certaine erreur entre les classes en calculant itérativement le degré d'appartenance et les centres des classes en utilisant les relations définies en dessous.

Les techniques de classification floues, comme les c-moyennes floues affectent chaque observation (pixel) à plus d'un cluster. Les degrés d'appartenance de chaque groupe sont généralement initialisés au hasard. À chaque itération, de nouveaux points centraux sont calculés sous forme de coordonnées moyennes des observations pondérées en fonction de leur degré d'appartenance au point central par l'équation (1.16).

$$V_i = \frac{\sum_{k=1}^n \mu_{ik}^m x_k}{\sum_{k=1}^n \mu_{ik}^m} \quad (1.16)$$

Après la mise à jour des points centraux, les degrés d'appartenance des observations doivent être mis à jour aussi bien, parce qu'ils sont inversement proportionnels à leurs distances à partir des points centraux correspondant. Ceci est habituellement fait en utilisant la formule suivante:

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{m-1}}} \quad (1.17)$$

Dans le cas d'une image : Où  $\mu_k(x)$  est le degré d'appartenance de l'observation  $x$  au cluster  $k$  et  $V_i$  est le point de la grappe  $k$  centrale ( $x$  et  $V_i$  sont des vecteurs).

- $x_k$  : représente le niveau de gris du  $k^{\text{ème}}$  pixel de l'image.
- $n$  : représente le nombre de pixels de l'image.
- $c$  : représente l'ensemble des points centraux de la grappe.
- $d$  : représente la distance Euclidienne.
- $m$  : le paramètre de flou

L'algorithme est répété jusqu'à ce que le changement global dans les affectations de points centraux ne dépasse pas une petite valeur  $\varepsilon$  arbitraire.

**II.11.3. Paramètre de contrôle du flou ( $m$ ) :** les valeurs utiles pour ce paramètre sont comprises entre 1,5 et 3 et il n'existe pas de fondement mathématique quant à son existence et à la valeur qui est affectée. Le plus souvent  $m=2$  se révèle adéquat. Dans le cas où  $m=1$  nous sommes dans le cas des C-means classiques.

**II.11.4. Inconvénient de la méthode [38] :**

- Les degrés d'appartenance sont des degrés relatifs. Autrement dit, l'appartenance d'un individu à une classe dépend de l'appartenance de cet individu aux autres classes.
- Les résultats de la segmentation dépendent de l'étape de l'initialisation.
- Les points aberrants (éloignés) peuvent avoir des valeurs d'appartenance élevées et ils peuvent affecter de façon significative l'estimation des centres des classes.
- les estimations des centres des classes ne correspondent pas aux centres réels ou typiques.
- Classification moins efficace en présence de bruit.

## II.12. Conclusion :

Nous avons pu voir dans ce chapitre quelques notions de base sur l'image numérique, nous avons présenté les méthodes de segmentation d'image ; contours et régions, et surtout la segmentation par classification non supervisée « clustering » qui tente d'obtenir des informations sans aucune connaissance préalable, ou intervention requise. Certaines de ces méthodes exigent le réglage de quelques paramètres tel que le seuil. La méthode des k-moyennes permet de regrouper dans le même cluster des objets dans des classes homogènes, quant à la méthode des C-moyennes floues, elle permet aux pixels d'appartenir à plusieurs clusters simultanément avec différents degrés d'appartenance. L'initialisation et le choix du nombre de classe sont importants, puisque ils ont une grande influence sur la qualité de la classification.

Nous nous sommes intéressé le plus aux les méthodes de segmentation d'image qui s'effectuent par la classification de pixels suivant un critère de similarité prédéfini.

Et pour finir, on doit dire que l'algorithme FCM est un algorithme bien adapté à l'identification des classes en connaissant le nombre de classe *a priori*.

### III. Introduction :

Le problème de la capture de l'imprécision présente dans le monde réel, est difficile à surmonter en utilisant la théorie des ensembles classiques seule. Par conséquent, plusieurs extensions pour définir la théorie ont été proposées, qui traitent des aspects différents de l'incertitude.

Dans ce chapitre nous mettons en lumière un algorithme hybride appelé les C-moyennes approximations floues (*en anglais* rough fuzzy C-means RFCM) présenté pour la segmentation des Images par Résonance Magnétique du cerveau. L'algorithme RFCM est basé sur les deux ensembles approximatifs et flous.

De ce fait, nous présenterons d'abord les notions nécessaires des ensembles flous, les ensembles approximatifs et l'hybride des deux ensembles qui, ce dernier forme un algorithme utile dans la classification.

#### III.1. La théorie des ensembles flous (fuzzy set theory) :

Les modèles dans notre cerveau peuvent être assez compliqués et également vagues, flous ou imprécis. La formulation et la résolution des problèmes du monde réel nécessitent des descriptions mathématiques de leur ambiguïté. Une approche distincte pour faire face à un raisonnement dans des circonstances incertaines est d'utiliser la théorie des ensembles flous, qui s'occupe de la subjectivité et l'imprécision [18] [31]. Cette théorie traite des sous-ensembles d'un univers du discours [31] où l'adhésion des membres est graduée, c'est-à-dire l'appartenance est exprimée par un degré d'appartenance, non sous forme d'une affirmation ou d'un démenti [14]. Cette propriété est exploitée en segmentation d'images, et plus précisément en classification où les classes sont représentées par des ensembles flous.

Cette fameuse théorie a été introduite en 1965 par le professeur Lotfi Zadeh. Zadeh a constaté que les ensembles classiques sont incapables de représenter des données subjectives.

Arnold Kaufmann, un des fondateurs de la théorie des ensembles flous et de la logique floue, écrit : « *la théorie des sous-ensembles flous pose le problème épistémologique suivant : est-il meilleur d'utiliser un modèle certain mais représente de trop loin le réel ou un modèle flou qui le représente mieux ?* ».

##### III.1.1. Ensembles classiques et ensembles flous:

La logique floue repose sur la théorie des ensembles flous, qui est une généralisation de la théorie des ensembles classiques. Autrement dit, les ensembles flous sont des extensions des ensembles classiques dans lesquels les éléments peuvent être soit des membres avec un degré d'appartenance de 1, soit des non-membres avec un degré d'appartenance de 0, par opposition aux ensembles flous dans lesquels les éléments peuvent avoir n'importe quel degré d'appartenance entre 0 et 1. Une fonction caractéristique qui assigne le degré d'appartenance aux éléments dans le domaine des ensembles flous, est appelée la fonction d'appartenance  $\mu_A(x)$  [1] [18].

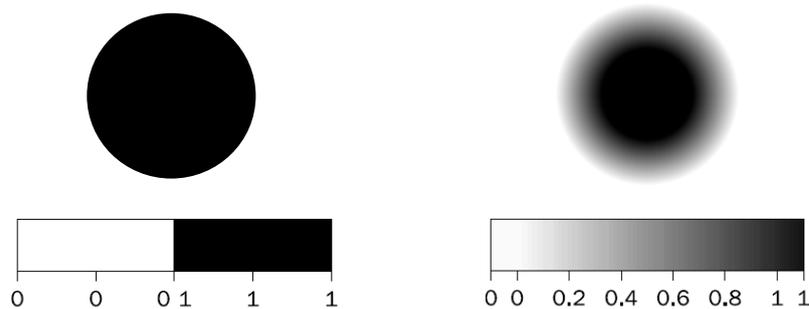


Figure 3.1 Ensemble classique sur la gauche; logique booléenne, et un ensemble flou sur la droite; le niveau de gris indique le degré d'appartenance

**Commentaire :** Contrairement à deux valeurs dans la logique booléenne ou binaire, la logique floue est à multi-valeurs. La logique floue utilise le continuum de valeurs logiques entre 0 et 1. Au lieu que ça soit représenté simplement en noir et blanc, elle emploie le spectre des couleurs, en admettant que les choses peuvent être en partie vraie et en partie fausse en même temps. Comme on peut le voir sur la figure 3.1, la logique floue ajoute une gamme de valeurs logiques à la logique booléenne.

### III.1.2. Concept des sous-ensembles flous :

Imaginons, maintenant, que la fonction caractéristique puisse prendre une valeur quelconque dans l'intervalle  $[0,1]$ . La notion d'appartenance peut prendre une extension intéressante. Dans le concept mathématique défini par l'expression suivante :

$$A^* = \{(x_1/0.2), (x_2/0), (x_3/0.3), (x_4/1), (x_5/0.8)\}$$

Le nombre placé après la barre est la valeur de la fonction caractéristique de l'élément. Ce concept est appelé sous-ensemble flou de E, noté par :  $A^* \subset E$

L'appartenance d'un élément à un sous-ensemble flou est notée par :

$$x_1 \in_{0.2} A^* ; \quad x_2 \in_0 A^* ; \quad x_4 \in_1 A^* .$$

C'est-à-dire que,  $A^*$  contient peu de  $x_1$ , ne contient pas  $x_2$  et contient  $x_4$  tout entier. Ce qui permet de construire une structure mathématique avec laquelle on peut manipuler des concepts assez mal définis.

Une définition plus rigoureuse de ce concept est donnée par Zadeh : Soit E un ensemble dénombrable ou non et x un élément de E, alors un sous-ensemble flou  $A^*$  de E est un ensemble de couples :

$$\{(x/\mu_{A^*}(x))\} ; \forall x \in E$$

Où  $\mu_{A^*}(x)$  est le *degré d'appartenance* de l'élément x au sous-ensemble  $A^*$ . La fonction  $\mu_{A^*}(x)$  prend ses valeurs dans un ensemble M appelé *ensemble d'appartenance*.

On dit que x prend ses valeurs dans M par la fonction  $\mu_{A^*} : x \xrightarrow{\mu_{A^*}} M$

**III.1.2.1. Définition d'un sous-ensemble flou :**

Soit X un espace de points également appelé univers du discours, et soit x un élément de X. un sous-ensemble flou A de X est caractérisé par une fonction d'appartenance  $\mu_A$  qui associe à chaque élément x de X un nombre réel dans l'intervalle [0,1] et qui représente le degré d'appartenance de cet élément à A. Ainsi, le sous-ensemble flou A de X est défini par :  $A = \{(x, \mu_A(x)), x \in X\}$  avec  $\mu_A: X[0, 1], \forall x \in X$ .

Selon les valeurs de  $\mu_A(x)$ , nous distinguons les trois cas suivants :

- $\mu_A(x) = 0$  non appartenance absolue de x à A
- $\mu_A(x) = 1$  appartenance absolue de x à A
- $0 < \mu_A(x) < 1$  appartenance graduée ou partielle de x à A

Si A est un sous-ensemble classique, la fonction d'appartenance qui lui est associée ne prendra que deux valeurs extrêmes, c'est-à-dire :

$$\mu_A = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases}$$

**III.1.2.2. La fonction d'appartenance :**

Dans un domaine discret  $X = \{x_i / i = 1, 2, \dots, n\}$  ou continu X, un sous-ensemble flou A de X peut être défini par un ensemble de paires : degré d'appartenance/ élément.

$$A = \mu_A(x_1)/x_1 + \mu_A(x_2)/x_2 + \dots + \mu_A(x_n)/x_n \quad \text{cas discret}$$

Un exemple numérique est donné dans le concept mathématique.

Chaque sous-ensemble flou peut être représenté par sa fonction d'appartenance. En général la forme de fonctions d'appartenance dépend de l'application, les plus usuelles sont : triangulaire, trapézoïdale, gaussienne et singleton respectivement comme le montre la figure ci- dessous.

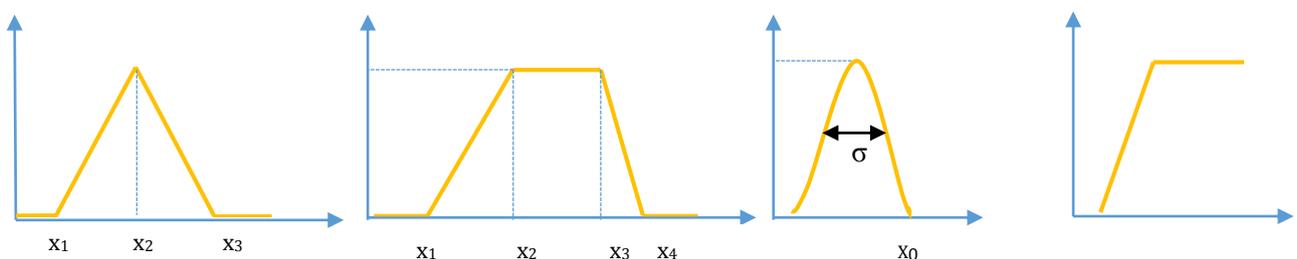


Figure 3.2 les formes des fonctions d'appartenance

- Fonction d'appartenance triangulaire :

Elle est caractérisée par trois paramètres  $x_1$ ,  $x_2$  et  $x_3$  correspondant respectivement à la borne inférieure, la borne supérieure et une valeur modale. Ce type de fonctions est défini comme suit :

$$\mu_A(x) = \begin{cases} \frac{x - x_1}{x_2 - x_1} & \text{si } x_1 \leq x \leq x_2 \\ \frac{x - x_3}{x_2 - x_3} & \text{si } x_2 \leq x \leq x_3 \\ 0 & \text{sinon} \end{cases}$$

- Fonction d'appartenance trapézoïdale :

Elle est définie par quatre paramètres  $x_1$ ,  $x_2$ ,  $x_3$  et  $x_4$ . Les paramètres  $x_1$  et  $x_4$  représentent respectivement la limite inférieure et la limite supérieure du support. Les paramètres  $x_2$  et  $x_3$  sont respectivement la borne inférieure et la borne supérieure du noyau. Cette fonction est définie par l'expression suivante :

$$\mu_A(x) = \begin{cases} \frac{x - x_1}{x_2 - x_1} & \text{si } x_1 \leq x < x_2 \\ 1 & \text{si } x_2 \leq x < x_3 \\ \frac{x - x_4}{x_3 - x_4} & \text{si } x_3 \leq x < x_4 \\ 0 & \text{sinon} \end{cases}$$

- Fonction d'appartenance gaussienne :

Elle est caractérisée par sa valeur centrale  $m$  et son écart type  $\sigma$ . La fonction d'appartenance gaussienne est définie par :

$$\mu_A(x) = \exp\left(-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2\right)$$

- fonction d'appartenance singleton définie par :

$$\mu_A(x) = \begin{cases} 1 & \text{si } x = x_0 \\ 0 & \text{ailleurs} \end{cases}$$

La fonction d'appartenance est une mesure :

- Du degré auquel un élément est membre d'un ensemble.
- Du degré d'appartenance.
- De la valeur de l'appartenance.
- Du degré de confiance.

### III.1.2.3. Caractéristiques des sous-ensembles flous :

La fonction d'appartenance décrivant un sous-ensemble flou est caractérisée par quatre propriétés :

**III.1.2.3.1. Le type :** la forme du nombre ou qui peut être triangulaire, trapézoïdale, gaussienne ou sigmoïdale.

**III.1.2.3.2. La hauteur :** soit un sous ensemble flou du référentiel X, la hauteur du sous ensemble flou A de X, notée  $h(A)$  est le plus fort degré avec lequel un élément de X appartient à A. formellement :

$$h(A) = \sup_{x \in X} (\mu_A(x))$$

Un sous-ensemble flou est dit normalisé s'il est de hauteur 1.

**III.1.2.3.3. Le noyau :** le noyau d'un sous ensemble flou A de X, noté  $N(A)$  est l'ensemble des éléments qui lui appartiennent totalement avec un degré égal à 1. Pour les fonctions de type triangulaire, le noyau est un singleton qui est appelé aussi valeur modale.

$$N(A) = \{x / \mu_A(x) = 1\}$$

**III.1.2.3.4. Le support :** le support d'un sous ensemble flou A de X, noté par  $Supp(A)$  est l'ensemble de tous les éléments qui lui appartiennent au moins un petit peu.

$$supp(A) = \{x / \mu_A(x) \neq 0\}$$

Cet ensemble décrit l'ensemble des éléments qui sont partiellement dans A.

**III.1.2.3.5. La cardinalité :** la cardinalité du sous ensemble flou A de X, notée par  $|A|$  est le nombre d'éléments appartenant à A pondéré par leur degré d'appartenance.

$$|A| = \sum_{x \in A} \mu_A(x)$$

**III.1.2.3.6. La  $\alpha$ -coupe :** le sous ensemble ordinaire  $A_\alpha$  de X associé à A pour le seuil  $\alpha \in [0,1]$ , est l'ensemble des éléments qui appartiennent à A avec un degré au moins égal à  $\alpha$ . On dit que  $A_\alpha$  est la  $\alpha$ - coupe de A.

$$A_\alpha = \{x \in X / \mu_A(x) \geq \alpha\}$$

$\mu_{A_\alpha}(x)$  Prend ses valeurs dans  $\{0,1\}$ .

La figure ci-dessous montre les différentes caractéristiques (noyau, support,  $\alpha$ -coupe, la hauteur) d'un ou ensemble flou A.

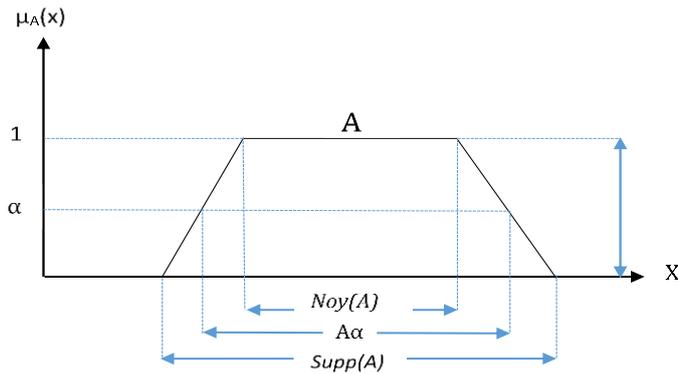


Figure 3.3 illustration des caractéristiques noyau, support,  $\alpha$ -coupe et hauteur d'un sous ensemble flou.

### III.1.2.4 Opérations simples sur les sous-ensembles flous :

Les opérateurs les plus courants appliqués aux ensembles flous sont la négation (complémentation), ET (minimum) et OU (maximum). Ces opérateurs flous décrivent comment des ensembles flous interagissent ensemble.

- *Inclusion* : Soient E un ensemble, M son ensemble d'appartenance associé et  $A_1^*$  et  $A_2^*$  deux sous-ensembles flous de E. On dit que  $A_1^*$  est inclus dans  $A_2^*$  si :

$$x \in E: \mu_{A_1^*}(x) \leq \mu_{A_2^*}(x)$$

- *Egalité* : Les sous-ensembles flous  $A_1^*$  et  $A_2^*$  sont égaux ( $A_1^* = A_2^*$ ) si et seulement si :

$$\mu_{A_1^*}(x) = \mu_{A_2^*}(x)$$

- *Complémentation* : Le complément permet de vérifier de combien un élément n'appartient pas à un ensemble.

Les sous-ensembles flous  $A_1^*$  et  $A_2^*$  sont complémentaires si :

$$\forall x \in E: \mu_{A_1^*}(x) = 1 - \mu_{A_2^*}(x)$$

- *Intersection* : L'intersection de deux ensembles, en logique floue, est un peu différente des méthodes classiques. On cherche à savoir de combien un élément est-il dans les deux ensembles. On utilise alors la valeur minimale d'appartenance pour calculer l'intersection.

On définit l'intersection de deux sous-ensembles flous,  $A_1^* \cap A_2^*$ , par le plus grand sous-ensemble flou contenu dans  $A_1^*$  et  $A_2^*$  à la fois, On écrit :

$$\forall x \in E: \mu_{A_1^* \cap A_2^*}(x) = \text{Min}(\mu_{A_1^*}(x), \mu_{A_2^*}(x))$$

- *Union* : En logique floue, l'union est le contraire de l'intersection. On cherche à savoir de combien un élément est-il dans l'un des deux ensembles. On utilise la valeur maximale d'appartenance.

On définit l'union de deux sous-ensembles flous,  $A_1^* \cup A_2^*$ , par le plus petit sous-ensemble flou qui contient  $A_1^*$  et  $A_2^*$  à la fois, On écrit :

$$\forall x \in E: \mu_{A_1^* \cup A_2^*}(x) = \text{Max}(\mu_{A_1^*}(x), \mu_{A_2^*}(x))$$

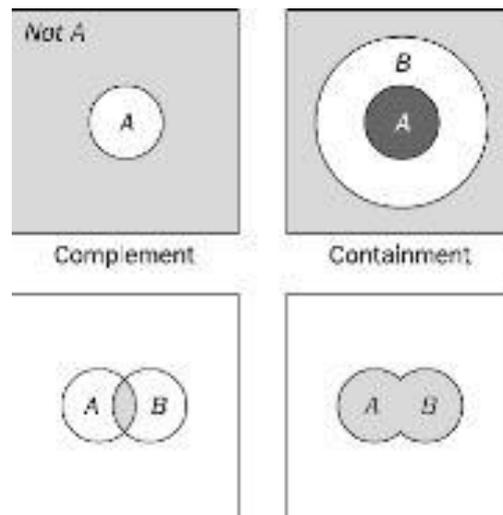


Figure 3.4 illustration sur les opérations sur les ensembles flous

### III.1.2.5 Les probabilités et la théorie des sous-ensembles flous :

Soit un ensemble  $E = \{a, b, c, d\}$ . On définit un sous-ensemble flou en affectant à chaque élément une valeur de la fonction d'appartenance, par exemple :

$$A^* = \{(a/0.3), (b/0.7), (c/0), (d/1)\}$$

Dans la théorie des probabilités, on affecte des nombres  $Pr \in [0,1]$  à des sous-ensembles ordinaires constituant une famille. Soit :

$$A = \{\emptyset, \{a\}, \{b\}, \{c\}, \{b, c\}, \{a, d\}, \{a, b, d\}, \{a, c, d\}, E\}.$$

### III.1.2.6 partition floue :

Un ensemble de sous-ensembles flous  $A_1, A_2, \dots, A_n$  définis sur un univers du discours  $X$  par les fonctions d'appartenance  $\mu_{A_1}(x), \mu_{A_2}(x), \dots, \mu_{A_n}(x)$ , est une répartition floue si et seulement si :

$$\forall x \in X \quad \sum_{i=1}^n \mu_{A_i} = 1$$

La définition des ensembles flous donne naissance au concept de variables linguistiques floues. En mathématiques classiques, les variables sont généralement numériques, mais dans la logique floue, les variables peuvent obtenir des conditions linguistiques comme des valeurs. Dans la section qui suit, nous allons donner une définition aux variables linguistiques.

### III.1.2.7. Variable linguistique :

Pour qu'il soit possible de raisonner simplement sur un problème, il faut tout d'abord spécifier clairement les connaissances disponibles. Les variables linguistiques permettent de décrire dans un cadre très général la connaissance acquise sur une variable, même lorsqu'elle est vague ou imprécise.

Une variable linguistique est une variable dont les valeurs sont des mots ou des citations dans un langage naturel, où l'ensemble de référence d'un mot du langage naturel s'appelle l'univers du discours  $U$ . Autrement dit, L'univers du discours d'un mot est un ensemble de termes qui évoquent le même concept mais à degrés différents. Une variable linguistique représente un état dans un système à étudier.

En général, les valeurs d'une variable linguistique peuvent être générées à partir d'un terme primaire comme « chaud », de son antonyme qui est le « froid », d'une collection de modificateurs comme « très, plus ou moins, moyen, etc. » et des connectifs « et » et « ou » [19] [50].

La figure illustre les fonctions d'appartenance de formes triangulaires ( $\mu_F(T)$ ,  $\mu_M(T)$ ,  $\mu_C(T)$ ,  $\mu_{TC}(T)$ ) caractérisant les valeurs (*froid*, *moyen*, *chaud*, *très chaud*) de la variable linguistique *température*.

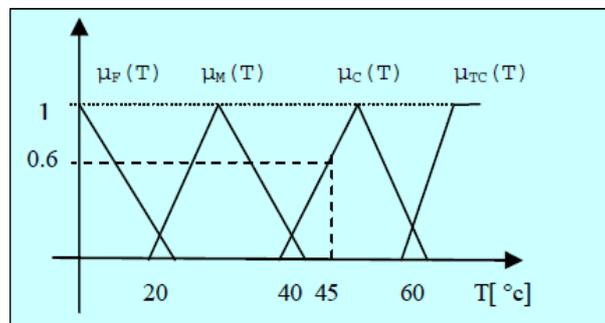


Figure 3.5 Fonctions d'appartenance caractérisant les prédicats flous : *Froid*, *Moyen*, *Chaud* et *Très Chaud*

- *Univers du discours* : gamme de température de 0°C à 60°C
- *Variables linguistiques* : la température
- *Valeurs linguistiques* : “froid”, “moyen”, “chaud”, “très chaud”

Les valeurs des variables linguistiques sont la traduction linguistique que de divers états de ces dernières tel que : froid, tiède et chaud, sont des valeurs de la variable linguistique température.

### III.1.2.8 Les règles floues et l'implication floue :

Habituellement, les règles floues sont déduites des expériences acquises par les opérateurs ou les experts. Ces connaissances sont traduites en règles simples pouvant être utilisées dans un processus d'inférence floue. Par exemple, si un expert exprime la règle «si la température de l'eau est chaude, il faut ajouter de l'eau froide», le système utilisera une règle du genre «si  $p$  alors  $q$ ».

Aujourd'hui, il est cependant possible de constituer une base de règles floues grâce à des méthodes d'apprentissage, sans avoir nécessairement besoin d'un expert humain.

Une règle floue est une déclaration de la forme suivante : **Si**  $x$  est  $A$  **alors**  $y$  est  $B$ . Où  $x$  et  $y$  sont des variables linguistiques, et  $A$  et  $B$  sont des valeurs linguistiques.

- La variable floue  $X$  appartient à la classe floue  $A$  avec un degré de validité  $\mu(x_0)$
- La variable floue  $Y$  appartient à la classe floue  $B$  à un degré qui dépend du degré de validité  $\mu(x_0)$  de la prémisse.

L'idée principale des systèmes basés sur la logique floue, est d'exprimer la connaissance humaine sous la forme de règles linguistiques de forme **Si...alors ...**. Chaque règle a deux parties :

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

La partie antécédente est la description de l'état du système. La partie conséquente exprime l'action que l'opérateur qui contrôle le système doit exécuter. Chaque règle floue est basée sur l'implication floue.

### III.1.2.9 Inférence floue :

Le mécanisme d'inférence le plus couramment utilisé est celui dit « de Mamdani ».

Les méthodes d'inférence, utilisées habituellement en logique classique, peuvent être généralisées dans le cadre de la logique floue pour permettre de raisonner lorsque les règles ou les faits sont connus de façon imparfaite [36]. Le principe de base de l'inférence dans la logique classique est le *modus ponens*, selon lequel on peut inférer la vérité d'une proposition  $B$  à partir de la vérité de la proposition  $A$  et de l'implication  $A \rightarrow B$ . C'est-à-dire que ça nous permet de déduire une nouvelle connaissance en se basant sur la connaissance d'un seul fait et d'une seule règle.

### III.1.2.10 Système d'inférence flou [22] [25] :

Un système d'inférence floue (SIF) permet d'encoder des connaissances sous une forme qui reflète la façon dont les experts pensent à un problème complexe. Le système flou peut être considéré comme un système logique qui utilise des règles linguistiques pour établir des relations entre ses variables d'entrée et de sortie. Il est formé de trois blocs comme l'indique la figure.

Le second bloc est le moteur d'inférence, constitué de l'ensemble de règles. Enfin, le bloc de défuzzification permet, si nécessaire, d'inférer une valeur nette, à partir du résultat de l'agrégation des règles.

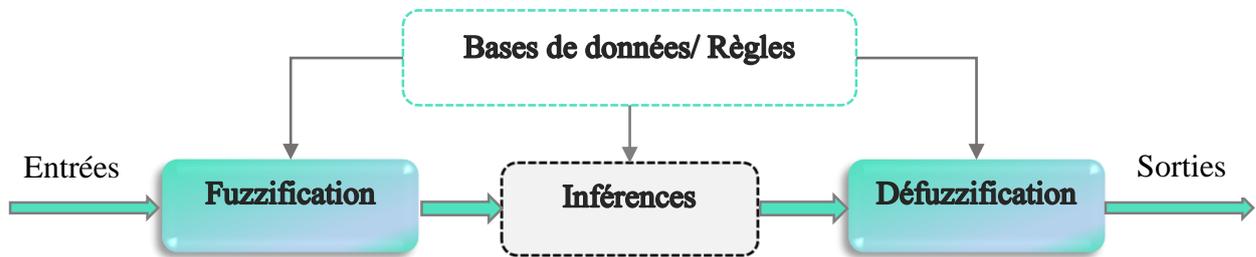


Figure 3.6 Structure d'un système d'inférence flou

- **Fuzzification**

Elle consiste à associer à chaque valeur d'entrée numérique, les degrés d'appartenance aux ensembles flous associés et prédéfinis dans la base de données du système flou [26]. Ce bloc réalise la transformation des entrées numériques en informations symboliques floues [28].

- **Inférence floue**

La phase d'inférence consiste à calculer le degré de vérité des différentes règles du système, en utilisant les formules données dans la phase de fuzzification, et à associer à chaque règle une valeur de sortie. Cette valeur de sortie dépend de la partie conséquente des règles qui peut prendre plusieurs formes. Donc, on peut dire que l'inférence floue est l'opération d'agrégation des règles floues [29].

- **Défuzzification**

En sortie de l'inférence, le système flou ne peut pas communiquer des valeurs floues qu'il peut seul exploiter. Il lui est donc nécessaire de fournir des valeurs précises, c'est le rôle de la défuzzification. Cette étape s'effectue toujours à l'aide des fonctions d'appartenance. A partir des degrés d'appartenance, on obtient autant de valeurs qu'il y a d'états [29].

### III.2. La théorie des ensembles approximatifs (rough set theory) :

La théorie des ensembles approximatifs (*en anglais* Rough Set Theory) est une méthode mathématique majeure développée par Pawlak en 1982 (Pawlak, 1982). Cette méthode traite l'incertitude de l'information qui présente quelques inexactitudes, incomplétude et bruits. Lorsque les informations disponibles sont insuffisantes pour déterminer la valeur exacte d'un ensemble donné, des approximations inférieures et supérieures peuvent être utilisées par l'ensemble approximatif pour la représentation de l'ensemble concerné.

**Enoncé** : un ensemble approximatif est une représentation imprécise d'un ensemble "croquant" (*crisp*) en termes de deux sous-ensembles (une paire de deux sous-ensembles): une approximation

inférieure et une approximation supérieure. De plus, les approximations ont pu elles-mêmes être imprécises ou floues.

### III.2.1. Notions de base sur les ensembles approximatifs

**Définition :** La théorie des ensembles approximatifs commence par la notion de l'espace d'approximation, qui est une paire  $\langle U, R \rangle$ , où  $U$  un ensemble non-vide (univers de discours) et  $R$  une relation d'équivalence sur  $U$ . La relation  $R$  décompose l'ensemble  $U$  en classes disjointe d'une manière à ce que deux éléments  $x, y$  sont dans la même classe ssi  $(x, y) \in R$ . Dénotons par  $U/R$  l'ensemble quotient de  $U$  par la relation  $R$ , et  $U/R = \{X_1, X_2, \dots, X_m\}$  où  $X_i$  est une classe d'équivalence de  $R$ ,  $i = 1, 2, \dots, m$ , si deux éléments  $x, y \in U$  appartiennent à la même classe d'équivalence  $X_i \in U/R$ , alors  $x$  et  $y$  sont appelés indiscernables. Les classes d'équivalence de  $R$  et l'ensemble vide  $\emptyset$  sont des ensembles élémentaires dans l'espace d'approximation  $\langle U, R \rangle$  [37].

### III.2.2. Systèmes d'information et de classification

Le point de départ des ensembles approximatifs [21] est un ensemble de données, qui est habituellement organisé dans une table, constitué d'objets (lignes dans le tableau) et les attributs (colonnes) [12], et ils sont appelés les systèmes d'information ou bases de données, ils réalisent la représentation de connaissances. Lorsque la classification est effectuée en fonction des caractéristiques de l'objet, chaque valeur d'attributs est associée à un groupe de valeur, et quand une valeur de chaque attribut est sélectionnée, une description d'un objet est donnée. Les opérateurs de base dans la théorie des ensembles approximatifs sont des approximations inférieures et supérieures, et ils sont utilisés pour définir la dépendance totale et la dépendance à la partie de la propriété dans les bases de données. Les données réduites est un concept très important dans la théorie des ensembles approximatifs.

**Définition (système d'information).** Un système d'information est un couple  $(U, A)$  peut être considéré comme un système  $IS = (U, A)$  où  $U$  est l'univers (un ensemble fini d'objets,  $U = \{x_1, x_2, \dots, x_m\}$ ) et  $A$  est un ensemble d'attributs (caractéristiques, variables). Chaque attribut  $a \in A$  (attribuer une appartenance à l'ensemble considéré d'attributs  $A$  défini une fonction d'information  $f_a : U \rightarrow V_a$ , où  $V_a$  est un ensemble de valeur de  $a$ , appelé le domaine de l'attribut  $a$  [18] [6].

**III.2.3. Système de décision :** Un système d'information peut être prolongé par l'inclusion des attributs de décision. Un tel système est appelé un système de décision.

### III.2.4. Relation d'indiscernabilité :

La relation d'indiscernabilité est un concept central dans la théorie des ensembles approximatifs, et est considérée comme une relation entre deux objets ou plus, où toutes les valeurs sont identiques par rapport à un sous-ensemble d'attributs. C'est une relation d'équivalence, où tous les objets identiques de l'ensemble sont considérés comme élémentaires.

Nous pouvons voir des éléments de l'univers avec les informations disponibles des éléments de l'univers. Par conséquent, les deux éléments décrits par les mêmes informations sont indiscernables [21].

**Définition :** Supposons que l'on nous donne un ensemble d'objets  $U$  appelé univers. Chaque sous-ensemble de fonctionnalités  $B \subseteq A$  induit une relation d'indiscernabilité:

$$\text{Ind}_B = \{(x, y) \in U \times U : \forall a \in B \ a(x) = a(y)\}$$

Si  $(x, y) \in I$ , alors  $x$  et  $y$  sont indiscernables.

La relation représente notre manque de connaissances sur les éléments de  $U$  [45].

Pour tout  $x \in U$ , il existe une classe d'équivalence  $[x]_B$  dans la partition de  $U$  définie par  $\text{Ind}_B$ .

La classe d'équivalence de  $\text{Ind}(B)$  est appelé ensemble élémentaire  $B$  parce qu'il représente les plus petits groupes discernables d'objets. Pour tout élément  $x_i$  de  $U$ , la classe d'équivalence de  $x_i$  par rapport  $\text{Ind}(B)$  est représentée comme  $[x_i]_{\text{Ind}(B)}$ . La construction des ensembles élémentaires est la première étape dans la classification avec des ensembles approximatifs [5].

### III.2.5. Les approximations inférieures et supérieures :

Lorsque les informations disponibles sont insuffisantes pour déterminer la valeur exacte d'un ensemble donné, des approximations inférieures et supérieures peuvent être utilisées par l'ensemble approximatif pour la représentation de l'ensemble concerné.

L'approche des ensembles approximatifs pour l'analyse des données repose sur deux concepts de base, à savoir les approximations inférieures et les approximations supérieures d'un ensemble [45].

- Les approximations inférieures sont une description des objets du domaine, qui appartiennent avec certitude aux sous-ensembles.
- Les approximations supérieures sont une description des objets qui, éventuellement appartiennent au sous-ensemble d'intérêt.

Les définitions formelles des approximations et les régions limites sont [22] :

$$\underline{apr}_p(X) = \cup\{x \in U : I(x) \subseteq X\} \quad (3.1)$$

$$\overline{apr}_p(X) = \cup\{x \in U : I(x) \cap X \neq \emptyset\} \quad (3.2)$$

$$bnd_p = \overline{apr}_p(X) - \underline{apr}_p(X) \quad (3.3)$$

La formule (3.1) signifie que l'approximation inférieur de l'ensemble  $X$ , est un ensemble d'objets  $x_i$  qui appartiennent à des ensembles élémentaires contenus dans  $X$  (c'est l'union de tous les ensembles élémentaires qui sont des sous-ensembles de  $X$ ), et l'approximation supérieure équation (3.2) est l'union de tous les ensembles élémentaires qui ont une intersection non vide avec  $X$  [39].

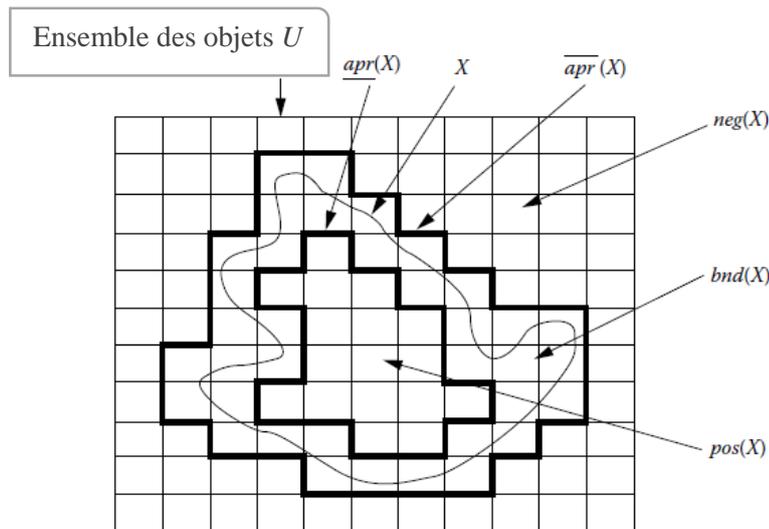


Figure 3.7 carte Esquisse pour les concepts de la théorie des ensembles approximatifs.

### III.2.6. Qualité de l'approximation ou degré de dépendance, et la réduction :

Pour mesurer la dépendance de la connaissance, la qualité de classification doit être définie [21]

**Définition :** Supposons  $X = \{X_1, X_2, \dots, X_n\}$  est une partition de l'univers  $U$ , où  $X_i (i = 1, 2, \dots, n)$  est une classe de  $X$ , et  $P \subseteq A$ , alors la qualité d'approximation de  $X$  est

$$\gamma_p(X) = \frac{\sum_{i=1}^n |\overline{apr}_p(X_i)|}{|U|} \quad (3.4)$$

Où  $|\cdot|$  dénote la cardinalité de l'ensemble, et la qualité de l'approximation  $\gamma_p(X)$  représente le rapport de tous les objets correctement classés par l'attribut défini  $P$  à tous les objets dans le système.

Le processus de réduction d'un tel système d'information que l'ensemble des attributs du système d'information réduite, est indépendant, et aucun attribut peut être éliminé plus loin sans perdre une partie des informations du système, le résultat est connu comme réduction. Nous devons obtenir la réduction d'un système d'information afin d'en extraire des connaissances d'un système d'information [12].

### III.2.7. Noyau et réduction des attributs :

Les concepts du noyau et réduction sont deux concepts fondamentaux de la théorie des ensembles approximatifs. Une façon d'augmenter l'efficacité de calcul consiste à réduire la taille des données en réduisant les attributs qui doivent être pris en compte [9]. La réduction est la partie essentielle d'un système d'information, qui peut discerner tous les objets discernables par le système d'information original. Le noyau est la partie commune de toutes les réductions [5].

**Définition (réduction).** Étant donné une tâche de classification liée à la cartographie  $C \rightarrow D$ , une réduction d'un sous-ensemble  $R \subseteq C$  tel que  $\gamma(C, D) = \gamma(R, D)$  et aucun sous-ensemble de  $R$  satisfait l'égalité analogue. [12]

**Définition (noyau ou core).** L'attribut  $c \in C$  est une caractéristique de base (core) par rapport à  $D$  si et seulement si elle appartient à tous les produits (reducts). On note l'ensemble de toutes les fonctions de base par  $\text{Core}(C)$ . Si l'on désigne par  $R(C)$  l'ensemble de tous les produits, nous pouvons mettre :

$$\text{Core}(C) = \bigcap_{R \in R(C)} R$$

Dans (Pawlak, 1991), Pawlak a discuté deux caractérisations numériques de l'imprécision d'un sous-ensemble  $X$  dans l'espace d'approximation  $\langle U, R \rangle$  : la précision et la rugosité.

La précision de  $X$ , notée  $\alpha_R(X)$  est simplement le rapport du nombre d'objets dans son approximation inférieure à celle de son approximation supérieure [37]:

$$\alpha_R(X) = \frac{\text{apr}_p(X)}{\text{apr}_p(X)} \quad (3.5)$$

La rugosité est dénotée  $\rho_R(X)$  est définie par :  $1 - \alpha_R(X) = 1 - \frac{\text{apr}_p(X)}{\text{apr}_p(X)}$  (3.6)

### III.3. L'hybridation des ensembles approximatifs avec les sous-ensembles flous :

#### III.3.1. Les ensembles approximatifs flous (rough fuzzy sets) :

Plusieurs problèmes de divers secteurs ont été effectivement résolus par l'utilisation de la FCM et ses différentes variantes. Mais, pour une utilisation efficace de l'algorithme dans diverses applications diversifiées, certaines modifications ou l'hybridation avec d'autres algorithmes sont nécessaires [20].

La théorie des ensembles flous et la théorie des ensembles approximatifs, sont deux théories qui se complètent mutuellement et constituent un des éléments importants de l'intelligence computationnelle.

Dubois a introduit le concept des ensembles flous approximatifs. Il est une extension d'un ensemble approximatif déduit d'un ensemble flou dans un espace croquant et approximatif. Dans l'ensemble flou approximatif, la classe de sortie est floue. La définition de l'approximation supérieure et l'approximation inférieure du rough ensemble flou  $FX$  suivante est donnée en fonction de sa théorie de base.

L'une des premières tentatives de l'hybride des deux théories est celle où des ensembles approximatifs sont exprimés par une fonction d'appartenance floue pour représenter les régions négatives, positives et les frontières. Tous les objets dans la région positive ont une appartenance de 1, et ceux qui appartiennent à la région frontière ont une appartenance de 0,5. Ceux qui sont contenus dans la région négative (et donc ne font pas partie de l'ensemble approximatif) ont une appartenance de zéro. En faisant ainsi, un ensemble approximatif peut être exprimé comme un ensemble flou.

**III.3.2. L'algorithme RFCM :**

Les détails de cet algorithme ont été rapportés dans (Maji et Pal, 2007a, c). L'algorithme de RFCM est basé sur les deux ensembles approximatifs et des ensembles flous [37].

**III.3.2.1. La fonction objectif :**

Soit  $\underline{apr}_p(X)$  et  $\overline{apr}_p(X)$  les approximations supérieures et inférieures du cluster  $X$ ,

Soit les équations (3.1), (3.2) et (3.4) définies dans la section IV.5.

Le RFCM partitionne un ensemble de  $n$  objets en  $c$  clusters en minimisant la fonction objectif.

$$J_{RF} = \begin{cases} \omega \times \underline{apr}_p + \tilde{\omega} \times \underline{bnd}_p & \text{si } \underline{apr}_p(X_i) \neq \emptyset, \underline{bnd}_p(X_i) \neq \emptyset \\ \underline{apr}_p & \text{si } \underline{apr}_p(X_i) \neq \emptyset, \underline{bnd}_p(X_i) = \emptyset \\ \underline{bnd}_p & \text{si } \underline{apr}_p(X_i) = \emptyset, \underline{bnd}_p(X_i) \neq \emptyset \end{cases} \quad (3.7)$$

$$\underline{apr}_p = \sum_{i=1}^c \sum_{x_j \in \underline{apr}_p(X)} \|x_j - v_i\|^2 \quad (3.8)$$

$$\underline{bnd}_p = \sum_{i=1}^c \sum_{x_j \in \underline{bnd}_p(X)} (\mu_{ij})^m \|x_j - v_i\|^2 \quad (3.9)$$

$v_i$  représente le centre du  $i^{\text{ème}}$  cluster  $X_i$ , les paramètres  $\omega$  et  $\tilde{\omega}$  correspondent à l'importance relative de la frontière inférieure et la région limite, et  $\omega + \tilde{\omega} = 1$ . Notons que,  $\mu_{ij}$  a le même sens d'appartenance que le c-moyennes flous [37].

Dans le RFCM, chaque cluster est représenté par un centroïde, une approximation inférieure, et une frontière floue. L'approximation inférieure influe sur le flou de la partition finale. Selon les définitions des approximations inférieures et les frontières des ensembles approximatifs, si un objet  $x_j \in \underline{apr}_p(X_i)$  alors  $x_j \in \overline{apr}_p(X_i), \forall k \neq i$ , et  $x_j \in X(X_i), \forall i$ .

Dans le RFCM, les valeurs d'appartenance des objets dans l'approximation inférieure sont  $\mu_{ij} = 1$ , tant dis que ceux dans la région limite sont les mêmes comme les c-moyennes flou. Autrement dit, l'algorithme RFCM partitionne d'abord les données en deux classes, approximation inférieure et limite. Seulement les objets situant dans la frontière sont fuzzifier.

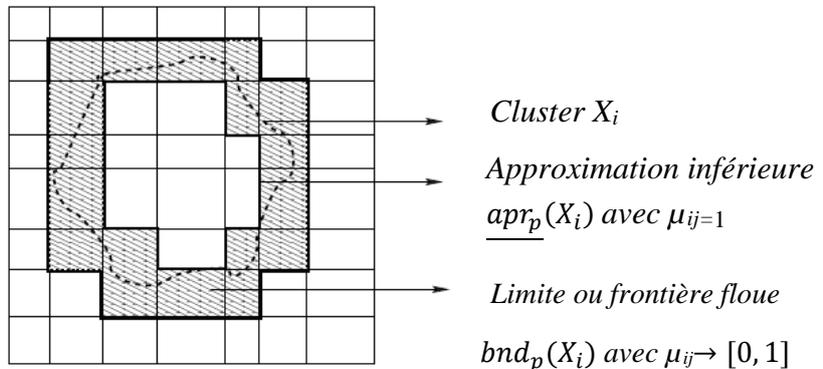


Figure 3.8 RFCM,  $X_i$  est représenté par une frontière inférieure croustillante et une frontière floue

L'algorithme RFCM est résumé comme suite.

**Algorithme 3** RFCM

**Etape1** attribuer des centroides initiales  $v_i$ , fixer le degré flou  $m$ , le seuil  $\varepsilon$ , fixer le compteur d'itération  $t = 1$

Répéter

**Etape2** calculer par  $\mu_{ij}$  l'équation  $\mu_{ij} = \left( \frac{\sum_{k=1}^c \frac{\|x_j - v_i\|^{2/(m-1)}}{\|x_j - v_k\|^{2/(m-1)}} \right)^{-1}$ ,  $i = 1, 2, \dots, c$ ;  $j = 1, 2, \dots, n$

Si  $\mu_{ij}$  et  $\mu_{ik}$  les deux grand degrés d'appartenance de  $x_j$  et  $(\mu_{ij} - \mu_{kj}) \leq \delta$ , alors  $x_j \in \underline{apr}_p(X_i)$  et  $x_j \in \underline{apr}_p(X_k)$ .

**Etape 4** sinon,  $x_j \in \underline{apr}_p(X_i)$ . De plus, par les propriétés des ensembles approximatifs,  $x_j \in \underline{apr}_p(X_i)$ .

**Etape 5** modifier  $\mu_{ij}$  considérant les régions inférieures et limites pour  $c$  clusters et  $n$  objets.

**Etape 6** calculer la fonction objectif  $J_{RF}$

**Etape 7** calculer les nouveaux centroides en utilisant l'équation

$$v_i^{RF} = \begin{cases} \omega \times C_1 + \tilde{\omega} \times D_1 & \text{si } \underline{apr}_p(X_i) \neq \emptyset, bnd_p(X_i) \neq \emptyset \\ C_1 & \text{si } \underline{apr}_p(X_i) \neq \emptyset, bnd_p(X_i) = \emptyset \\ D_1 & \text{si } \underline{apr}_p(X_i) = \emptyset, bnd_p(X_i) \neq \emptyset \end{cases}$$

$C_1 = \frac{1}{|\underline{apr}_p(X_i)|} \sum_{x_j \in \underline{apr}_p(X_i)} x_j$ , où  $|\underline{apr}_p(X_i)|$  représente la cardinalité de  $\underline{apr}_p(X_i)$ .

Et  $D_1 = \frac{1}{n_i} \sum_{x_j \in \underline{apr}_p(X_i)} (\mu_{ij})^m x_j$ ; où  $n_i = \sum_{x_j \in bnd(X_i)} (\mu_{ij})^m$

Jusqu'à stabilisation des centres.

La performance de l'algorithme de RFCM dépend de la valeur de  $\delta$ , qui représente la taille des granules de classification floue rugueuse. Pour la mise en œuvre de cet algorithme, nous avons appliqué la définition suivante pour  $\delta$  dire, la différence moyenne de deux plus hautes adhésions de tous les objets dans l'ensemble de données:  $\delta = \frac{1}{n} \sum_{j=1}^n (\mu_{ij} - \mu_{kj})$ .

#### **III.4. Conclusion :**

Dans ce chapitre, un algorithme FCM (Fuzzy C-Means) basé sur les ensembles approximatifs pour la segmentation d'image est présenté. Les processus de l'approche comprennent deux étapes. Dans un premier temps, un ensemble de centre du cluster est construit par la théorie de la réduction (le noyau des ensembles approximatifs). Dans cette étape, une table décision est conçu en premier lieu, où un ensemble central initial du cluster qui contient des granules avec des frontières mal définies est traité comme un objet, et chaque granule est traitée comme l'attribut de l'objet. La discernabilité des premiers ensembles de centres de cluster en termes d'attributs est ensuite calculée sous la forme d'une matrice de discernabilité. Ensuite, en utilisant la théorie des ensembles approximatifs, un certain nombre de règles de décision est généré à partir de la matrice de discernabilité. Les règles représentent des clusters approximatifs de points dans l'espace original. Dans la deuxième étape, l'ensemble du centre de cluster éliminé est entrée au FCM comme le centre de la grappe initiale pour l'évaluation de la segmentation, où les fonctions d'appartenance floue sont modélisées par une règle et utilisées pour calculer la similarité de chaque pixel d'image. Les résultats expérimentaux démontrent l'efficacité de la méthode présentée. Nous discuterons ces résultats dans le chapitre qui suit.

#### **IV. Introduction :**

Une méthode de segmentation est censée trouver des ensembles qui correspondent à des structures ou des régions d'intérêt dans l'image médicale anatomiques distinctes. Il n'est pas caché que le succès d'un système d'analyse d'image dépend de la qualité de la segmentation.

Dans l'analyse d'images médicales pour le diagnostic, la segmentation est souvent nécessaire comme une étape préliminaire. Cependant, la segmentation d'image médicale est une tâche complexe et difficile en raison de la nature intrinsèque des images. Le cerveau a une structure complexe, et particulièrement sa segmentation précise est très importante pour la détection de tumeurs, des tissus nécrotiques, et de lésion, afin de prescrire un traitement approprié

Malgré les avancées technologiques dans le domaine médical et en particulier dans l'imagerie médicale, l'étude du cerveau humain est un problème ardu et reste un sujet de recherche de forte actualité, du fait de l'évolution des techniques d'imagerie. Une des modalités d'imagerie les plus couramment utilisées, à laquelle nous sommes intéressés dans le cadre de ce mémoire, est l'Imagerie par Résonance Magnétique (IRM), qui est devenue un outil indispensable pour tout examen clinique, elle présente l'avantage d'être non invasive et permet l'acquisition d'images bi ou tridimensionnelles sur lesquelles différents contrastes sont possibles. Cette modalité permet en outre la réalisation d'études du cerveau aussi bien anatomiques que fonctionnelles grâce aux techniques d'IRM.

##### **IV.1. Segmentation des tissus cérébraux (MB, MB, LCR) :**

Pour mener à bien ces études il est nécessaire de développer des systèmes permettant d'interpréter automatiquement les images cérébrales fournies par la modalité d'imagerie à résonance magnétique. Interpréter une image cérébrale consiste généralement à localiser précisément sur cette image les différents éléments constitutifs du cerveau, c'est-à-dire, selon le niveau de description symbolique désiré pour l'application, les tissus cérébraux ou les différentes structures anatomiques composées de ces tissus. La tâche principale à effectuer consiste donc, souvent, à segmenter l'image, c'est-à-dire à étiqueter chaque pixel selon le tissu ou la structure qu'il contient majoritairement. C'est une tâche complexe, rendue difficile par la taille élevée et le caractère tridimensionnel des données, et la complexité de l'anatomie cérébrale humaine [7].

##### **IV.2. L'anatomie cérébrale [37] :**

Cette section définit les termes et concepts essentiels qui permettent de mieux comprendre ce que l'on observe avec l'imagerie cérébrale.

L'encéphale est la partie du système nerveux contenue dans la boîte crânienne et reposant sur la base du crâne. Il comprend le cerveau, le cervelet et le tronc cérébral (voir Figure) :

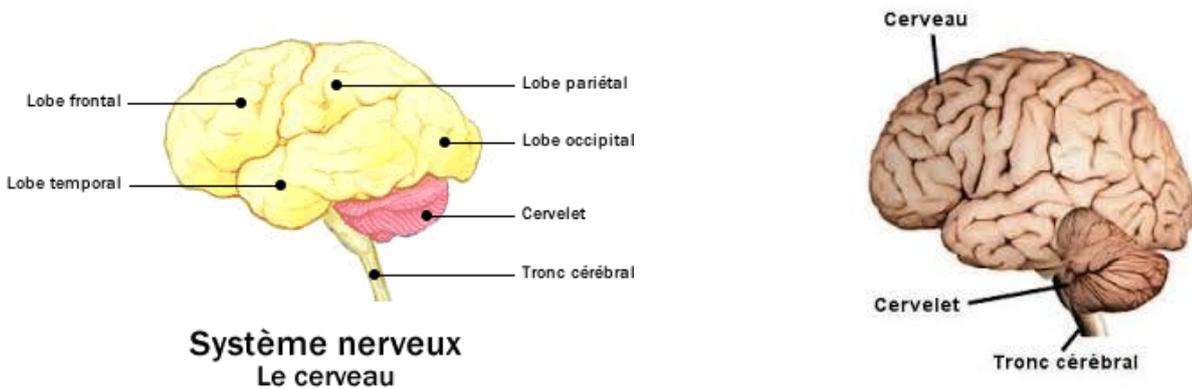


Figure 4.1 illustrant l'anatomie cérébrale

#### IV.2.1. Le cerveau [47] :

C'est un organe qui constitue la majeure partie de l'encéphale et est divisé en 2 hémisphères cérébraux : l'un à droite et l'autre à gauche. La surface du cerveau présente de nombreux replis, avec un grand nombre de circonvolutions limitées par des sillons. Certains sillons plus profonds, les scissures, permettent de diviser les hémisphères en 4.

Les hémisphères cérébraux constituent la partie la plus importante du cerveau. Ils sont le siège de la raison et de la créativité. Ils sont divisés en quatre parties ou lobes :

- Le lobe occipital est situé à l'arrière des hémisphères. Il est responsable de la vision.
- Le lobe pariétal qui reçoit les informations relatives au toucher et à l'orientation spatiale.
- Le lobe temporal contient les centres de l'audition, du goût et de la mémoire.
- Le lobe frontal responsable de la coordination des activités motrices volontaire. Il contient les centres chargés du contrôle musculaire, mais aussi des mouvements rythmiques coordonnés de la tête et de la gorge, comme ceux consistant à mâcher, lécher ou avaler. Le lobe frontal contient également les centres de la pensée, de la mémoire, du raisonnement et des associations. Selon certains chercheurs, il serait également le siège de la personnalité.

#### IV.2.2. Le cervelet :

Il est situé en parallèle sur deux grandes voies nerveuses : celles qui amènent les messages sensoriels vers les zones du cortex qui en font l'analyse ; et celles qui partent du cortex et descendent vers les muscles pour les faire se contracter. Le cervelet est en partie impliqué dans la coordination des mouvements du corps.

#### **IV.2.3. Le tronc cérébral :**

Il représente un carrefour majeur du système nerveux central entre le cerveau et le cervelet. Il est responsable en particulier de la régulation de la respiration et du rythme cardiaque. C'est également un centre de passage des voies motrices et sensitives, ainsi qu'un centre de contrôle de la douleur.

#### **IV.3. Les tissus du cerveau :**

Le cerveau contient principalement trois substances : le liquide céphalo rachidien (LCR), la matière grise (MG) et la matière blanche (MB).

##### **IV.3.1. Le liquide céphalo-rachidien (LCR) :**

Il est le liquide dans lequel baignent le cerveau et le cervelet et remplit le système ventriculaire. Il est absorbé par le système veineux cérébral et continuellement renouvelé. Ses principaux rôles sont :

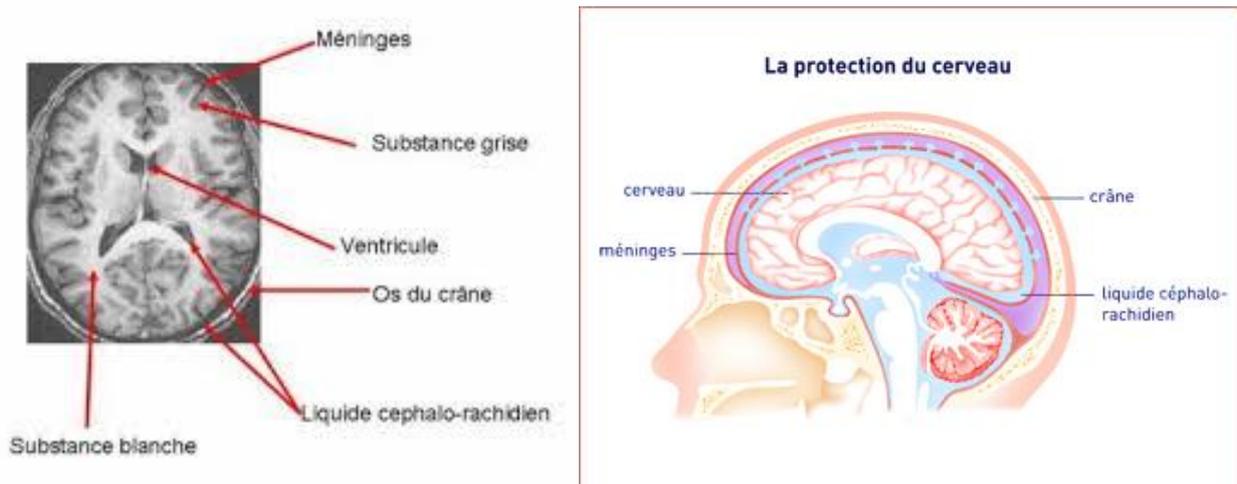
- La protection mécanique du système nerveux central contre les chocs par amortissement des mouvements.
- La protection contre les infections, car il contient les médiateurs de l'immunité humorale et cellulaire.
- Le transport des hormones entre les différentes régions éloignées du cerveau.

##### **IV.3.2. La matière grise (MG) :**

Il contient des corps cellulaires des neurones avec leur dense réseau de dendrites de synapses et de tissus de soutien. Elle se répartit en deux types de structures: le cortex et les noyaux gris centraux. Le cortex caractérisé par de nombreuses dépressions appelées sillons. Il est formé de cellules dont le nombre est estimé à plus de dix milliards, et qui sont disposées en couches superposées. Les noyaux gris sont des regroupements de substance grise.

##### **IV.3.3. La matière blanche (MB) :**

Elle est constituée d'axones (fibres de cellules) qui transmettent des messages entre les neurones par l'établissement de la connexion entre les corps cellulaires du cortex et d'autres parties du cerveau.



(a) plan axial

(b) plan sagittal

Figure 4.2 Coupe du cerveau mettant en évidence les trois matières principales

#### IV.4. L'Imagerie par Résonance Magnétique (IRM) :

L'imagerie par résonance magnétique est une technique d'imagerie médicale basée sur le phénomène de résonance magnétique nucléaire. Un examen qui permet de compléter le diagnostic de certaines pathologies, fournissant des images tridimensionnelles d'une partie du corps, notamment du cerveau et en coupe bidimensionnelle de grande précision anatomique, les images faites sont des images dynamiques permettant au chirurgien en l'occurrence de visualiser la pathologie et de proposer un traitement adéquat. L'IRM est le seul examen qui permet de voir s'il y a eu un accident vasculaire, grâce à sa capacité de voir à l'intérieur du cerveau lui-même. Elle utilise un champ magnétique (aimant) et des ondes radio. Aucune radiation ionisante n'est émise. Son principe consiste à réaliser des images du corps humain grâce aux nombreux atomes d'hydrogène qu'il contient [7] [51].

#### IV.5. L'observation du cerveau :

Le cerveau peut être représenté par des coupes bidimensionnelles selon plusieurs angles de vue. Il existe principalement trois axes anatomiques qui permettent de réaliser les coupes dites coronale, axiale, et sagittale

- La coupe coronale : elle est acquise sur un plan perpendiculaire aux plans des coupes axiales et coronales. C'est une vue de face ou frontale (divise le corps en deux parties antérieure et postérieure).
- La coupe axiale : correspond quasiment à un plan horizontal. En imagerie par résonance magnétique, elle correspond à un plan perpendiculaire à l'axe du champ magnétique principal.
- La coupe sagittale : concerne l'image acquise sur un plan parallèle au plan de symétrie du cerveau : le plan inter hémisphérique. Il s'agit d'une vue latérale. (divise le corps en deux parties gauche et droite).

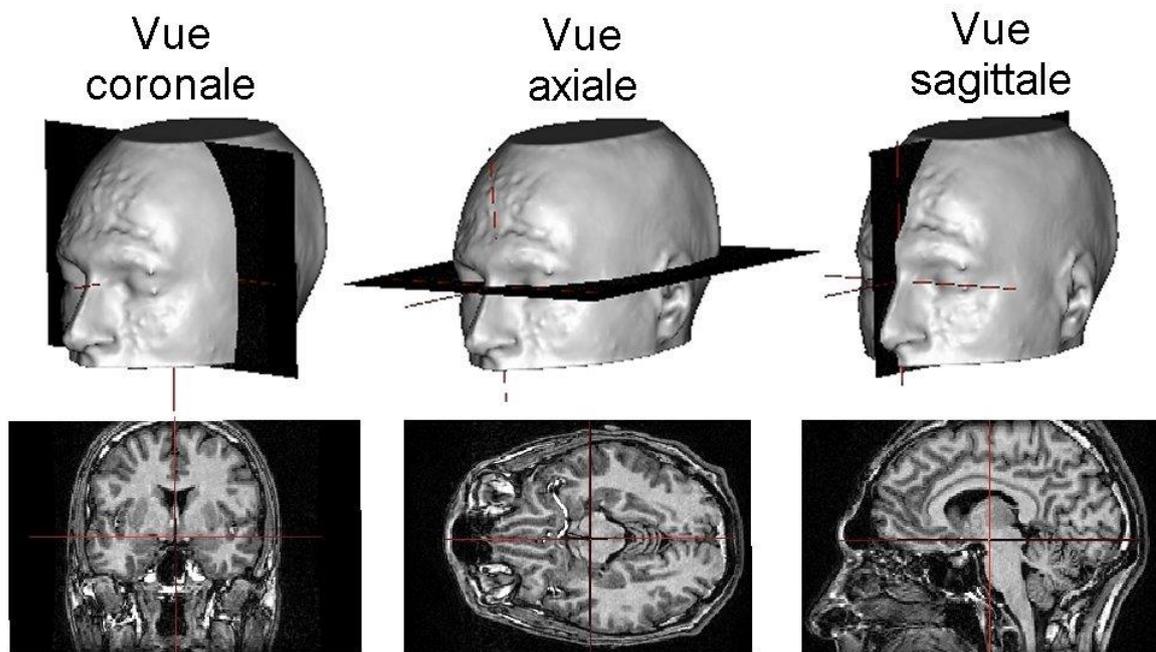


Figure 4.3 les trois coupes IRM du cerveau

## IV.6. Analyse des résultats expérimentaux et discussion :

### IV.6.1. Présentation de la base de données utilisée :

Dans cette section, des résultats expérimentaux sur des images de la base de données BrainWeb [53] de l'institut neurologique de l'Université McGill de Montréal sont décrites. Le site web de BrainWeb permet de simuler des IRM cérébrales avec différents niveaux de bruit et d'inhomogénéités. Ces simulations sont générées à partir d'une vérité terrain qui correspond à la classification d'une image cérébrale (de résolution millimétrique) en différentes classes correspondant aux différents tissus et structures.

Il y a deux algorithmes avec lesquels nous avons appliqué la segmentation des images cérébrales à résonance magnétique, le FCM et RFCM. Notons que le RFCM utilisé dans ces tests est obtenu en modifiant le FCM selon le principe de fonctionnement du RFCM. Dans ces tests, le nombre d'éléments d'objet dans chaque image à partir de l'analyse, disant manuelle a été considéré comme étant le nombre de classes à référencer qui est de quatre, qui correspondent à la matière blanche (MB), la matière grise (MG), le liquide céphalo-rachidien (LCR) et l'arrière-plan. Dans tous ces tests les pixels de l'arrière-plan sont ignorés. Et le degré flou étant fixé à  $m=2$ .

Les tests ont été réalisés sur Matlab version 7.9.0.529 (R2009b) 32-bit, exécutés sur un PC Intel® Pentium® CPU N3540 @ 2.16GHz 2.16GHz dual core.

**IV.6.2. Etude d'images sans bruit :**

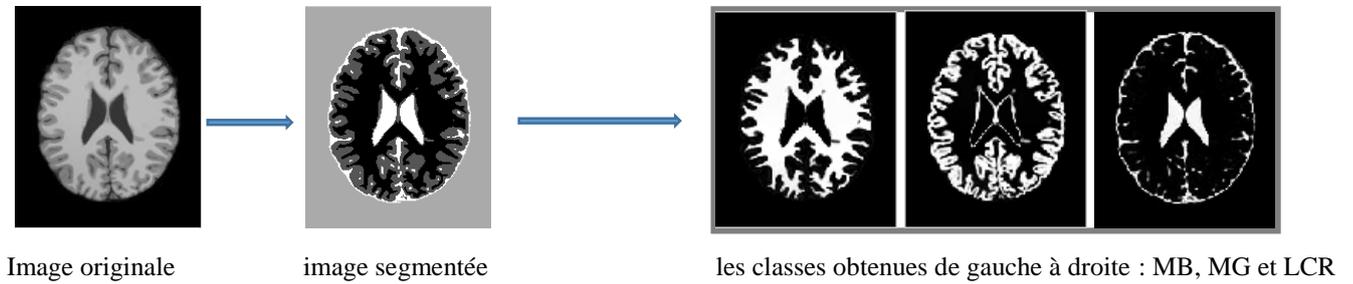


Figure 4.4 résultat de la segmentation par le FCM d'une image sans bruit

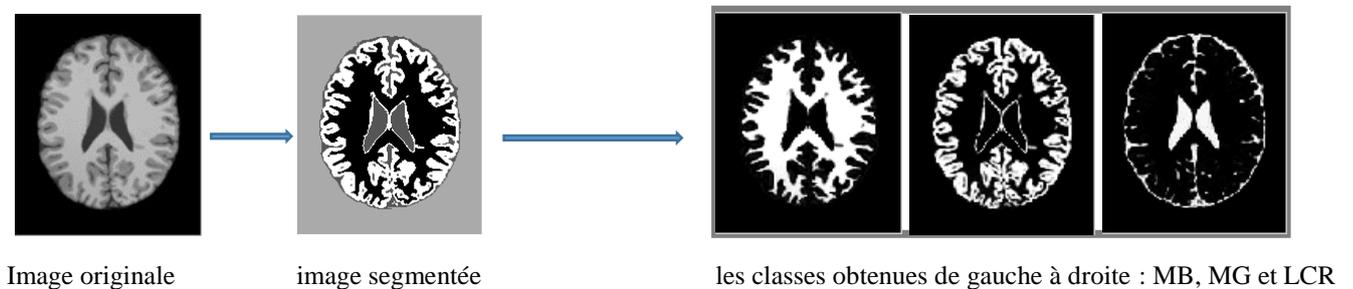


Figure 4.5 résultat de la segmentation par RFCM d'une image sans bruit

**IV.6.3. Etude d'image avec différents bruits :**

– **Bruit Gaussien de moyenne nulle et variance 0.002**

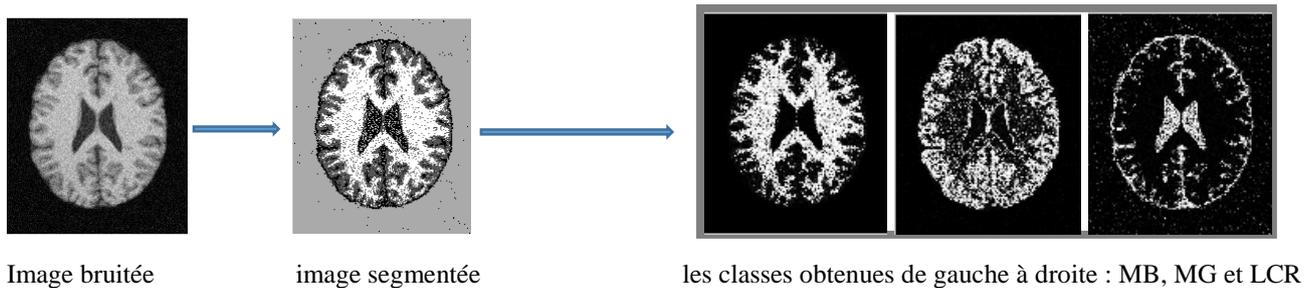


Figure 4.6 résultat de la segmentation par le FCM d'une image bruitée par un bruit gaussien

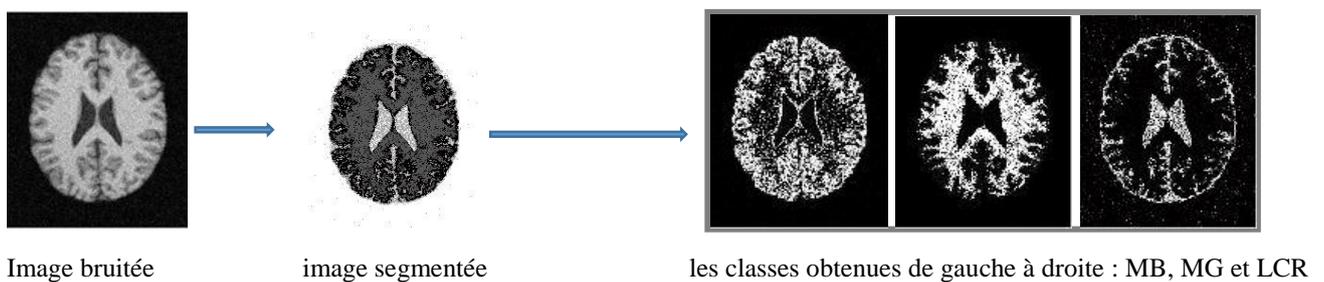


Figure 4.7 résultat de la segmentation par le RFCM d'une image bruitée par un bruit gaussien

– **Bruit Salt & Pepper de densité 0.02**

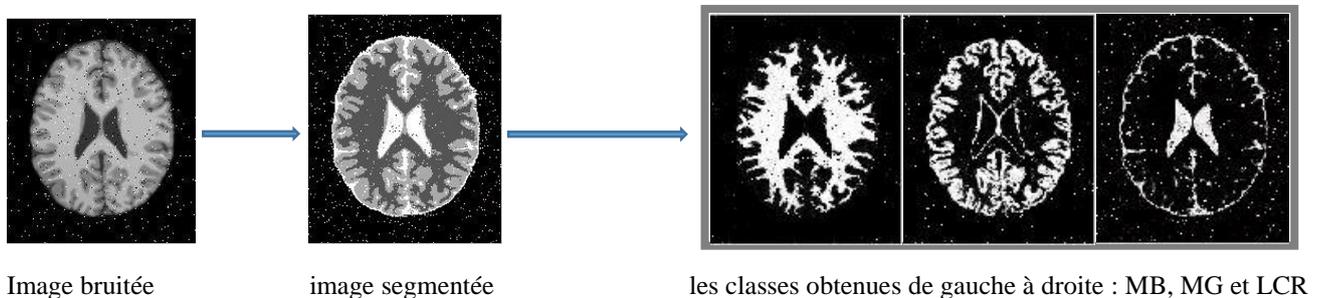


Figure 4.8 résultat de la segmentation par le FCM d'une image bruitée par le bruit Salt & Pepper

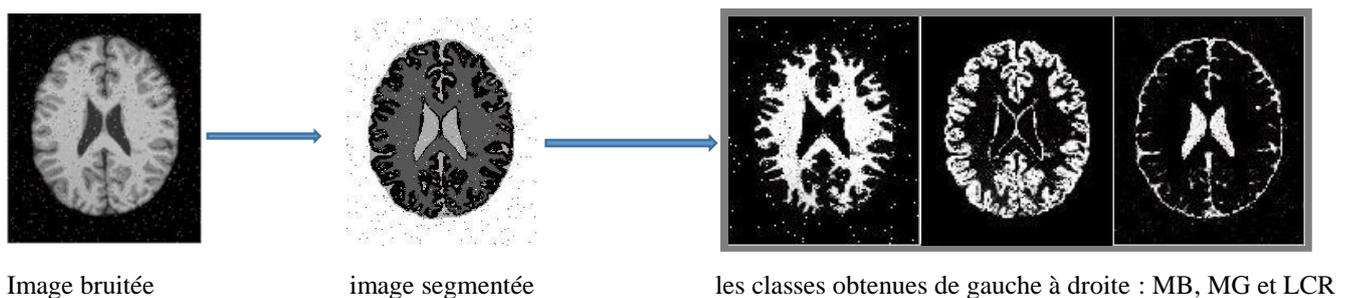


Figure 4.9 résultat de la segmentation par le RFCM d'une image bruitée par le bruit Salt & Pepper

Les figures (4.4, 4.5, 4.6, 4.7, 4.8, 4.9) illustrent les résultats obtenus après segmentation des différents tissus cérébraux en coupe axiale de l'image en cause.

**IV.6.4. Critère d'évaluation choisit :**

Un critère quantitatif d'évaluation de la qualité de la classification, est un indice de validité que nous utilisons pour la base de données médicale. Nous choisissons comme indicateur de la qualité de la classification le CR (Classification Rate) représentant le taux de pixels bien classés. Après l'exécution des deux algorithmes, nous avons comparé les résultats obtenus avec des images de vérité terrain qui sont exprimés dans le tableau ci-dessous.

Le CR est le rapport suivant :

$$CR = \frac{\text{nombre de pixels bien classés}}{\text{nombre total de pixels}}$$

CR(%)	Sans bruit			Bruit Gaussien var=0.1			Bruit Salt & Pepper d=0.02		
	MB	MG	LCR	MB	MG	LCR	MB	MG	LCR
<b>FCM</b>	98.8237	97.7595	99.0045	94.9054	92.6955	85.4546	97.1968	95.5088	97.4845
<b>RFCM</b>	98.8237	97.7595	99.0045	94.8316	92.7107	88.1406	97.1968	95.5165	97.4845

Tableau 4.1 Classification Rate (CR) obtenu par le FCM et le RFCM pour les différentes classes (MB, MG, LCR)

Les résultats obtenus en appliquant le FCM et le RFCM sur l'image non bruitée, sont exactement les mêmes pour les trois classes de la MB, la MG et LCR. Comme le montre le tableau ci-dessus les deux algorithmes donnent une bonne qualité de classification, vu que les pourcentages des pixels bien placés sont proches de la vérité terrain.

Selon les résultats de la classification des pixels de l'image bruitée avec un bruit gaussien de variance 0.1, on remarque que le classifieur RFCM a été plus performant que le FCM dans la segmentation de MG et le LCR.

Quant à l'application de ces deux algorithmes sur l'image bruitée avec le bruit Salt & Pepper de densité de 0.02, la qualité de classification du classifieur RFCM dans la segmentation de la MG est bien meilleure que celle faite par le classifieur FCM.

L'algorithme RFCM permet de cerner les bons points appartenant à chaque classe un peu plus précisément que le FCM.

#### IV.7. conclusion

Nous avons présenté dans ce dernier chapitre sous forme d'une étude comparative, les résultats de la segmentation d'image par la classification floue et par un deuxième classifieur hybride.

Les deux algorithmes de segmentation par classifications utilisés donnent différentes classification avec différentes images. Les résultats obtenus confirment l'intérêt de l'approche d'hybridation par rapport à l'approche floue prise indépendamment. Nous avons pu constater qu'en présence du bruit, la segmentation devient inefficace et se dégrade, et que la puissance de la machine où l'exécution est faite, à son tour influence sur la qualité de la classification.

L'algorithme hybride, RFCM est robuste en terme d'immunité au bruit, qualité de classification, mais non pas en terme de temps, vu que celui-là à plus de calcul à effectuer pour minimiser la fonction objectif.

Sur la base des résultats obtenus de la classification, il semble être efficace pour résoudre le problème de classification d'utiliser une approche hybride combinant des ensembles approximatifs et des ensembles flous, tous deux appartenant au domaine de la recherche de l'intelligence computationnelle.

---

## *Conclusion générale*

Nous avons abordé dans ce mémoire des techniques de l'intelligence computationnelle qui est un ensemble de méthodes de calculs inspirées de la nature, et qui ciblent à résoudre les problèmes complexes de la vie réelle, et qui ne peuvent pas être résolus par les mathématiques classiques vu l'incertitude et l'imprécision de ces problèmes. C'est là que se trouve le noyau des techniques de l'intelligence computationnelle, qu'est ce qui est d'aussi passionnant que d'insérer l'intelligence de l'humain dans une machine et la conception d'algorithmes, pour qu'elle donnent des solutions et des modélisations des problèmes, en effectuant des calculs aussi complexes que l'humain seul, ne pourra pas faire, au moins dans les délais de la contrainte du temps. Elle aide l'humain à prendre des décisions, ce qui nous amène vers un tout autre aspect, celui des machines intelligente. Récemment, ces techniques de l'intelligence computationnelle ont été utilisées dans les applications d'imagerie médicale, et elles se sont révélées être avantageuses par rapport aux approches classiques, en particulier lorsque les solutions classiques sont difficiles ou impossibles à formuler et à analyser, ce qui est le cas de l'image médicale.

Nous nous sommes focalisé le plus sur la logique floue parce que, plus complexe est un système, plus il implique un comportement intelligent, plus il est probable que la logique floue fournira une bonne approche, ce qui est le cas dans la segmentation d'image. En effet, les propriétés des ensembles flous sont les utilisées dans des algorithmes pour la segmentation d'image. Mais en dehors de ça, il faudra dire que les applications de la logique floue sont diverses, puisqu'elle est en mesure de faire des prédictions ou des décisions concernant des événements futurs.

Après avoir compris la source d'inspiration des techniques de l'intelligence computationnelle, nous avons pu comprendre leur utilité dans ce qui est l'objet du mémoire, qui est de trouver une bonne approche de classification appliquée sur des images par résonance magnétique (IRM) afin de segmenter les tissus du cerveau en trois classes distinctes, à savoir (MB, MG et LCR), vu les résultats obtenus, nous pouvons constater l'adaptabilité de l'algorithme des C-moyennes flous dans l'identification des classes. Cet algorithme est d'autant plus performant que nous connaissons le nombre de classes *a priori* et ça, de plus de sa simplicité algorithmique et sa rapidité d'exécution. Mais cela n'empêche qu'il n'y ait des points de vulnérabilité, car il reste sensible aux bruits et assujetti à l'initialisation des centres des classes.

Le second test consistait en l'introduction d'une variante qui est les ensembles approximatifs dans le FCM pour la segmentation d'images.

Par la théorie de réduction, les centres des clusters initiaux réduits sont définis comme entrée au FCM pour une évaluation des segments, ce qui est très utile pour surmonter les inconvénients de la segmentation par le FCM unique, et puis sa dépendance excessive sur le choix initiale des centres.

---

Nous pouvons obtenir de meilleurs résultats expérimentaux sur des images sans bruit et avec différents bruits qui renforceront la théorie disant que le RFCM est plus performant que le FCM en effectuant plusieurs tests sur différentes bases de données, d'images réelles, ceci s'explique par le fait que la variabilité d'une image présente une limite pour la qualité de la segmentation.

Nos perspectives, ont pour but l'amélioration de ces algorithmes et du coup, la qualité de classification en y remédiant relativement aux contraintes et inconvénients des algorithmes de segmentation d'image, ceci dit, adopter une métrique comme celle de *Mahalanobis*, l'utilisation des métaheuristiques qui consiste à autoriser une détérioration temporaire de l'objectif, permettant ainsi de quitter un minimum local, pour l'initialisation des centres de classes, et l'ajout de la composante spatiale pour le RFCM.

## **Références bibliographiques**

- [1] A. Agah, « *Medical Application of Artificial Intelligence* », CRC Press, 2014.
- [2] A. Mekhmoukh, « *segmentation d'image par classifieur non supervisé* », mémoire magister, université de Béjaia, 2008.
- [3] A. Konar, « *Artificial Intelligence and Soft Computing, Behavioral and Cognitive Modeling of the Human Brain* », Edition CRC Press LLC, 2000.
- [4] Andries P. Engelbrecht, « *Computational Intelligence An introduction* », WILEY 2002.
- [5] B. Walczak, D.L. Massart, « *rough sets theory* », ChemoAC, Chemometrics and Intelligent Laboratory Systems 47, Tutorial, university of Brussel, ELSEVIER, 1999.
- [6] B. Balasko, J. Abonyi and B. Feil, « *Fuzzy clustering toolbox and Data Analysis Toolbox For Use with Matlab* ».
- [7] B. ALI, « *mise en œuvre d'une technique automatique de segmentation de sillons corticaux* », Université Abou-Bakr Belkaid-Tlemcen, 2011.
- [8] B. Scherrer, « *Segmentation des tissus et structures sur les IRM cérébrales : agents markoviens locaux coopératifs et formulation bayésienne* », Rapport, Grenoble, 2008.
- [9] C. Fiorio, « *Approche interpixel en analyse d'images : une topologie* », thèse, Université de Montpellier II, 1995.
- [10] C. Hung, H. Purnawan, B. Kuo and S. Letkeman, « *Advances in Geoscience and Remote Sensing* », *Multispectral Image Classification Using Rough Set Theory and Particle Swarm Optimization* », Southern Polytechnic State University, National Taichung University, 2009.
- [11] E. Lebarbier, T. Mary-Huard, « *Classification non supervisée* », AggroParisTech.
- [12] G. Schaefer et Hassanian, « *Computational Intelligence in Medical Imaging Techniques and Applications* », CRC Press, 2009.
- [13] Jang, J. R., Sun, C. and Mizutani, E., *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, Prentice-Hall, Englewood Cliffs, NJ, pp. 7-9, 1997.
- [14] Jelena Godjevac, « *idées nettes sur la logique floue* », PPUR presses polytechniques Amazon France, 1999.
- [15] J. Bezdek, L. Hall, L. Clarke, « *Review of MR Image Segmentation Techniques using Pattern Recognition* », Medical Physics vol. 20, NO. 4, 1993.
- [16] J.C. Atine « *méthodes d'apprentissage flou : Application à la segmentation d'images biologiques* », thèse, Institut National des Sciences Appliquées, Toulouse, 2005.
- [17] J.C. Dunn, « *A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters* », vol 3 (1974).
- [18] L. A. Zadeh, « *Toward a Restructuring of the foundations of Fuzzy Logic* », University of California, Berkeley, pp 1676-1677, 1998.
- [19] L. A. Zadeh, « *fuzzy logic* », IEEE, p84, April 1988.

- [20] Lakhmi C. Jain, S. Patnaik, N. Ichalkaranje, « *Intelligent Computing, Communication and devices* », proceeding of ICCD 2014, volume2, Springer, 2015.
- [21] L. Jian et S. Liu et Y. Lin « *Hybrid Rough Sets and Applications in Uncertain Decision-Making* », CRC Press, 2011.
- [22] L. Rutkowski, « *computational intelligence : methods and techniques* », Springer, 2005.
- [23] L. Reznik, « *Fuzzy Controllers* », NEWNES, 1997.
- [24] L. KHODJA, « *Contribution à la Classification Floue non Supervisée* ». Thèse de Doctorat, université de Savoie, France, 1997.
- [25] Michael Negvinetsky, « *Artificial Intelligence, a guide to intelligent system* », ADDISON WESLEY, 2002.
- [26] M. MORDJAOUI, "Modélisation des effets électromagnétiques, Apport de la logique floue et neuro-floue ". Thèse de Doctorat, Université El-hadj Lakhdar –BATNA. Juin 2008.
- [27] N. RICHARD, « *Une approche située, coopérative et décentralisée pour l'interprétation d'images cérébrales par RMN* », thèse, Institut National Polytechnique de Grenoble, 2004.
- [28] N. Siddique, H. Adeli, « *Computational Intelligence : Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing* », WILEY, 2013.
- [29] O. GUENOUNOU, « *Méthodologie de conception de contrôleurs intelligents par l'approche génétique- application à un bioprocédé* », Thèse de Doctorat, Systèmes Automatiques, Université Toulouse III - Paul Sabatier, 2009.
- [30] PROCEEDINGS OF THE IEEE, VOL. 89, NO. 9, SEPTEMBER 2001, « *Special Issue on Industrial Innovations Using Soft Computing* », IEEE journals and Magazines, pp1239 – 1241.
- [31] Richard Jensen et Qiang Chen, « *computational intelligence and feature selection, Rough and Fuzzy Approches* », IEEE press series on computational intelligence and feature selection, WILEY, 2008.
- [32] Russell, Eberhart, Y. Shi, « *Computational Intelligence : Concepts to Implementations* », MORGAN KAUFFMAN, 2007.
- [33] Rutkowski, Leszek « *Computational Intelligence: Methods and Techniques* ». Springer, July 2006.
- [34] Rédha TIR, « *Data mining en assurance : Quelques Utilisations* », DGE, IV forum des Assurances, Alger, 2005.
- [35] R. Cant, J. Churchill, D. Al-Dabass, « *Using Hard And Soft Artificial Intelligence Algorithms To Simulate Human Go Playing Techniques* », I. J. of SIMULATION Vol. 2 No 1, The Nottingham Trent University, p 31-49, 2001.
- [36] S. Belattaf, « *Aspects de Segmentation et de Classification dans le Data Mining mémoire de magister en informatique, application à des études de Marketing* », université de Béjaia, 2005.
- [37] S.K. Pal et J.F. Peters « *Rough Fuzzy image analysis : foundation and methodology* », CRC Press, 2010.
- [38] S. Moussa, T. Lyazid, M. Abdelouaheb, « *Système Coopératif de Classification Floue Possibiliste avec Rejet d'Ambiguïté : Application à la segmentation d'images IRM* », 4th International Conference on Computer Integrated Manufacturing CIP'2007 03-04, université de Sétif, November 2007, p2.

- [39] S. Russell et P. Norving, « *Intelligence Artificielle : plus de 500 exercices* », springer, 2010.
- [40] S. L. Horowitz and T. Palvidis, « *Picture Segmentation by a Tree Traversal Algorithm* », Journal. ACM, vol.23, p 370, 1976.
- [41] S. Nebti, « *Optimisation par écosystème artificiels : application à la segmentation d'images* », thèses de Doctorat, Université de Constantine, 2007.
- [42] S. Ara Begum, O. Mema Devi « *A Rough Type-2 Fuzzy Clustering Algorithm for MR Image Segmentation* » *International Journal of Computer Applications (0975 – 8887) Volume 54– No.4, September 2012.*
- [43] Troisième conférence internationale sur l'intelligence collective computationnelle - Technologies et Applications, à Gdynia, en Pologne, 2011.
- [44] Y. LIM, S.U. LEE, « *On the color image segmentation Algorithm based on the thresholding and the fuzzy c-means techniques* ». Pattern Recognition, article, vol 23 Issue 9, p935-952, NY, 1990.
- [45] Zdzisław Pawlak, « *Databases and Rough Sets* », V. W. Marek Department of Computer Science University of Kentucky Lexington, KY 40506, p8.
- [46] <http://www.larousse.fr/encyclopedie>
- [47] <http://alp.developpez.com/tutoriels/intelligence-artificielle/reseaux-de-neurones/>
- [48] [https://fr.wikipedia.org/wiki/R%C3%A9solution\\_spatiale\\_des\\_images\\_matricielles](https://fr.wikipedia.org/wiki/R%C3%A9solution_spatiale_des_images_matricielles)
- [49] <http://www.bel.utcluj.ro/dce/didactic/sln/sln.htm>
- [50] <http://www.bel.utcluj.ro/dce/didactic/sisd/sisd.htm>
- [51] <http://www.bel.utcluj.ro/dce/didactic/tice/tice.htm>
- [52] <http://www.doctissimo.fr/html/sante/imagerie/irm.htm>
- [53] [www.bic.mni.mcgill.ca/brainweb/](http://www.bic.mni.mcgill.ca/brainweb/)



## ***Résumé***

L'intelligence computationnelle est un ensemble de calculs inspirés de la nature et des approches pour résoudre les problèmes complexes du monde réel, dont la modélisation mathématique classique n'est pas efficace. Les méthodes utilisées sont proches de la manière du raisonnement de l'humain à savoir la logique floue, les réseaux neuronaux et les algorithmes génétiques. L'objet de ce mémoire est l'utilisation de quelques techniques qu'elles soient individuelle ou combinées dans la segmentation d'image, la logique floue en est une. La segmentation est une opération de traitement d'image de bas niveau qui consiste à partitionner une image en régions homogènes. L'approche classification fournit aussi une partition de l'image en classes en regroupant des pixels ayant des niveaux de gris similaires. Dans ce mémoire, nous avons étudié l'algorithme FCM basée sur les ensembles flous, et le RFCM qui est un algorithme hybride des ensembles flous et les ensembles approximatifs, dans la segmentation des images cérébrales appelées (IRM). Des tests sur des images IRM montrent la supériorité de ces approches pour la réduction des effets.

## ***Abstract***

Computational Intelligence is a set of calculations inspired from nature and approaches to solving complex problems known real world, the classical mathematical modeling is not effective. The methods used are similar in the way of human reasoning namely fuzzy logic, neural networks and genetic algorithms. The purpose of this paper is the use of some techniques even if they are individually or combined in image segmentation, fuzzy logic is one the techniques used in image segmentation. Segmentation is a low-level image processing operation which consist in partitioning an image into homogeneous regions. The classification approach also provided a partition of the image into classes by grouping pixels having similar levels of gray. In this thesis, we studied the FCM algorithm based on fuzzy sets, and RFCM which is a hybrid algorithm of fuzzy sets and rough sets in the segmentation of brain images called (MRI). Tests on MRI images show the superiority of these approaches to reducing the effects.