

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE FARHAT ABBAS – SETIF
(UFAS). (ALGERIE)

MEMOIRE

Présenté à la Faculté des Sciences de l'Ingénieur
Département d'Informatique
Pour l'Obtention du Diplôme de

MAGISTER

Option : Sciences et Technologies de l'Information et de la Communication
Par

MR : Moussa SEMCHEDINE

Thème

Système Coopératif Hybride de Classification dans un SMA :
« Application à la segmentation d'images IRM »

Soutenu le : 17/12/2007

devant la commission d'examen :

Pr : MOSTEFAI Mohamed

Prof à l'université de Sétif

Président

Pr : BENMAHAMMED Khier

Prof à l'université de Sétif

Examineur

Dr : BOUKERRAM Abdallah

MC à l'université de Sétif

Examineur

Dr : MOUSSAOUI Abdelouahab

MC à l'université de Sétif

Rapporteur

REMERCIEMENTS

Tout d'abord, louanges à dieu pour nous avoir permis d'avoir les capacités physiques et mentales, nous permettant de réaliser ce modeste mémoire et nous l'implorons afin que notre travail soit couronné de succès.

Je tiens à remercier particulièrement :

- Mon encadrant monsieur MOUSSAOUI ABDELOUAHEB qui a toujours suivi ce travail avec intérêt et abnégation.*
- Les docteurs Dr : A. SEMCHEDINE, le Dr : W. BOUAMAMA et le Dr : M .DIAF pour leur précieuse collaboration et leur utile assistance.*
- Professeur K. BOUATOUICHE de l'université de Rennes pour son aide.*
- Messieurs le président et les membres du jury, d'avoir bien voulu nous faire l'honneur de juger ce travail.*
- Monsieur L .TOUMI pour sa coopération dans la réalisation de ce travail.*

Enfin, nos vifs remerciements à tous ceux qui, de près ou de loin, ont contribué et rendu ce travail possible.

Dédicace

Le présent mémoire est dédié à :

- Mes parents pour les encouragements qu'ils m'ont prodigués.*
- Tous mes enseignants pour le savoir, la connaissance et surtout la générosité sans lesquels rien n'aurait été possible.*
- A tous les étudiants du 3^{ème} LMD SEGC, LMD ST.*
- Tous les malades auxquels nous souhaitons un prompt rétablissement.*
- Notre chère Algérie pour les efforts qu'elle a consenti pour le développement et l'épanouissement des sciences.*
- A tous les martyres (mes oncles Semchedine Saci, Semchedine Abdelhamid)*

Sommaire :

Introduction	- 4 -
1. Quelques éléments d'anatomie cérébrale	- 4 -
1.1. Le cerveau :	- 4 -
1.2. Les principaux tissus cérébraux [LAR 06]	- 4 -
1.2.1. Le liquide céphalo-rachidien	- 4 -
1.2.2. La matière grise	- 4 -
1.2.3. La matière blanche	- 6 -
2. Observation du cerveau	- 7 -
• Coupes axiales	- 7 -
• Coupes sagittales	- 7 -
• Coupes coronales	- 7 -
3. IRM (Imagerie par Résonance Magnétique)	- 8 -
3.1. Principe général	- 8 -
3.2. Principe physique	- 9 -
3.3. Phénomène de la résonance	- 9 -
3.4. Relaxation et temps de relaxation	- 9 -
3.5. Paramètres de séquence	- 10 -
3.5.1. Temps d'écho	- 10 -
3.5.2. Temps de répétition	- 11 -
3.5.3. Angle de basculement	- 11 -
3.6. Séquences IRM	- 11 -
3.6.1. Image pondérée en densité de protons (ρ)	- 12 -
3.6.2. Image pondérée en T2	- 12 -
3.6.3. Image pondérée en T ₁	- 12 -
3.7. Défauts des images IRM (artefacts)	- 12 -
3.7.1. Bruit	- 13 -
3.7.2. Mouvement	- 13 -
3.7.3. Variations du champ magnétique (inhomogénéité RF)	- 13 -
3.7.4. Effets de volume partiel	- 13 -
Conclusion	- 14 -
Introduction	15
1. Applications et objectifs de la segmentation	15
2. Spécificités de la segmentation de l'IRM cérébrale	16
3. Les différentes méthodes de segmentation	17
3.1. Approches régions	17
3.1.1. Seuillages	17
3.1.2. Croissance de régions	18
3.1.3. Morphologie mathématique	19
3.2. Approches contours	20
3.2.1. Méthodes dérivatives	20
3.2.2. Modèles déformables	21
3.3. Segmentation par classification	22
3.3.1. Méthodes supervisées	22
3.3.1.1. Segmentation bayésienne	22
3.3.1.2. Segmentation Markovienne	24
3.3.1.3. Algorithme des k plus proches voisins	26
3.3.1.4. Réseaux de Neurones	27

3.3.2.	Méthodes non supervisées (Automatiques).....	29
o	Génération de fonctions d'appartenance	29
3.3.2.1.	Algorithmes de classification non flous	29
3.3.2.2.	Algorithme des C-moyennes floues (FCM)	30
3.3.2.3.	Algorithme de classification possibiliste.....	32
3.3.2.4.	Variations autour des C-moyennes floues.....	34
	Conclusion.....	35
	Introduction	- 37 -
1.	Définitions	- 37 -
2.	Objectifs et intérêts de la coopération	- 37 -
3.	Types de coopération [GER 99]	- 38 -
3.1.	Coopération par initialisation (séquentielle).....	- 38 -
3.2.	Coopération par fusion d'informations (parallèle).....	- 38 -
3.3.	Coopération par rétroaction	- 38 -
4.	Etat de l'art	- 40 -
4.1.	Coopération séquentielle	- 40 -
4.1.1.	Coopération séquentielle (Bayésienne\Morphologiemathé\Contour actif) .	- 41 -
4.1.2.	Coopération séquentielle (Morphologie mathé\bayésienne\Croissance)	- 41 -
4.1.3.	Approche coopérative (Mean-shift \ FCM).....	- 44 -
4.2.	Coopération par fusion	- 46 -
4.2.1.	Approche basée sur la théorie des jeux [BOZ 94].....	- 46 -
4.2.2.	Coopération Contour\ Contour	- 48 -
4.2.3.	Coopération Champ de Markov\ Contour	- 48 -
4.2.4.	Approche coopérative croissance de régions\contours.....	- 49 -
4.3.	Coopération Hybride	- 50 -
4.3.1.	Approche coopérative hybride Floue\croissance de régions	- 51 -
4.3.2.	Approche coopérative hybride [GER 99]	- 53 -
	Conclusion.....	- 56 -
	Introduction	- 57 -
1.	Historique	- 57 -
2.	Les Agents	- 58 -
2.1.	Notion d'agent	- 58 -
2.2.	Caractéristiques des Agents.....	- 59 -
2.3.	Architecture des agents [MAN 02]	- 60 -
2.4.	Capacités d'un agent.....	- 60 -
2.5.	Types d'agents.....	- 61 -
2.5.1.	Agent cognitif.....	- 61 -
2.5.2.	Agent réactif	- 62 -
2.5.3.	Agent hybride	- 62 -
2.6.	Agent et objet	- 62 -
2.7.	Agent et systèmes experts	- 62 -
2.8.	Programmation orientée agents (POA)	- 63 -
3.	Les systèmes multi-agents	- 63 -
3.1.	Définitions	- 63 -
3.2.	Caractéristiques des SMA	- 64 -
3.3.	Différentes classes des SMA	- 64 -
3.3.1.	Le système Tableau noir.....	- 65 -
3.3.2.	Les systèmes hiérarchisés.....	- 65 -

3.3.3.	L'approche totalement distribuée	- 66 -
3.4.	L'interaction dans les SMA	- 66 -
3.4.1.	Notion d'auto-organisation	- 67 -
3.4.2.	Notion de coopération	- 67 -
3.4.3.	Notion d'adaptation	- 68 -
3.4.4.	La communication	- 68 -
3.4.5.	La négociation	- 69 -
4.	Apports des SMA pour la segmentation d'images	- 69 -
4.1.	Représenter et organiser les informations	- 70 -
4.1.1.	L'hétérogénéité des informations manipulées	- 70 -
4.1.2.	La représentation et l'organisation des informations	- 70 -
4.2.	Extraire et gérer l'incertitude de nouvelles informations (apprendre)	- 71 -
4.2.1.	L'extraction de nouvelles informations	- 71 -
4.2.2.	Segmentation d'image, un processus incrémental	- 71 -
4.3.	Focaliser et combiner les traitements	- 71 -
4.3.1.	Segmentation d'image, un processus distribué	- 71 -
4.3.2.	Segmentation d'image, un processus coopératif	- 72 -
4.4.	Contrôler et coordonner les traitements	- 72 -
4.4.1.	Définition de la notion de contrôle	- 72 -
4.4.2.	Coordination des traitements	- 72 -
5.	Les approches multi-agents proposées pour la segmentation	- 73 -
5.1.	Image de type quelconque	- 73 -
5.2.	Image IRM	- 74 -
	Conclusion	- 75 -
	Introduction	- 77 -
1.	Choix de l'algorithme	- 77 -
1.1.	Quel type de méthode ?	- 77 -
1.2.	C-moyennes floues ou algorithme possibiliste ?	- 78 -
1.2.1.	Interprétation des degrés d'appartenance	- 78 -
1.2.2.	PCM et imagerie par résonance magnétique	- 80 -
1.2.3.	Limites du FCM	- 80 -
1.2.4.	Le Rejet d'ambiguïté [MEN 98]	- 81 -
1.3.	L'algorithme développé	- 84 -
2.	Choix des paramètres de l'algorithme	- 84 -
2.1.	Initialisation de l'algorithme	- 84 -
2.2.	Détermination du nombre de classes	- 85 -
2.3.	Choix du paramètre m	- 86 -
2.4.	Choix de la distance	- 86 -
2.5.	Détermination des paramètres de pondération η_i	- 87 -
2.6.	Choix des vecteurs forme	- 88 -
3.	Algorithmes utilisés	- 88 -
4.	Pourquoi une architecture multi-agent ?	- 91 -
5.	La plate-forme multi agents	- 92 -
5.1.	Caractéristiques de MAGIQUE	- 92 -
5.2.	Différentes méthodes de communication entre agents	- 95 -
5.3.	Le Routage des messages	- 96 -
5.4.	Les avantages de Magique	- 97 -
	Conclusion	- 97 -

Introduction	- 100 -
1. Les images réelles et simulées utilisées pour l'évaluation	- 100 -
1.1. Les images réelles.....	- 100 -
1.2. Les fantômes (images de synthèse)	- 100 -
2. Evaluation et étude comparative.....	- 102 -
2.1. Le protocole d'évaluation.....	- 102 -
2.2. Taux de recouvrement	- 103 -
3. Résultats	- 106 -
3.1. Images de synthèse	- 106 -
3.2. Images réelles	- 109 -
Conclusion.....	- 116 -
1. Historique	- 121 -
2. Définition.....	- 121 -
3. Pourquoi DICOM ?	- 121 -
4. Caractéristiques de la norme DICOM [IVA 06].....	- 122 -
5. Organisation des données dans un fichier DICOM.....	- 123 -
6. Quelques éléments importants du format DICOM.....	- 124 -
7. Modalités supportées par DICOM.....	- 124 -
8. Classes de Service actuellement disponibles dans la norme	- 125 -
9. Conclusion.....	- 125 -

Liste des figures

Figure 1: Structures anatomiques de la matière grise.....	- 5 -
Figure 2: Coupes IRM du cerveau.....	- 6 -
Figure 3: Différentes structures du cerveau.....	- 7 -
Figure 4: Les trois axes de coupe pour la visualisation du cerveau.....	- 7 -
Figure 5 : Acquisition par IRM.....	- 8 -
Figure 6 : Schéma fonctionnel de l'IRM.....	- 9 -
Figure 7: Phase de relaxation.....	- 10 -
Figure 8: L'angle de basculement.....	- 11 -
Figure 9: Les Séquences IRM, (a) : Image pondérée en ρ , (b) : Image pondérée en T_2	- 12 -
Figure 10 : L'inhomogénéité RF.....	- 14 -
Figure 11 : Problème du volume partiel.....	-17-
Figure 12 : Image IRM segmentée par une approche région.....	-19-
Figure 13 : Segmentation, approche contour.....	-21-
Figure 14 : Segmentation par modèle déformable. (a) : Image originale,.....	-21-
Figure 15 : Segmentation par méthode bayésienne.....	-23-
Figure 16 : Structure d'un neurone artificiel.....	-28-
Figure 17 : La coopération par initialisation (séquentielle).....	- 39 -
Figure 18 : Coopération par fusion (parallèle).....	- 39 -
Figure 19: Coopération par rétroaction.....	- 40 -
Figure 20 : Exemple de coopération séquentielle.....	- 42 -
Figure 21 : Segmentation coopérative séquentielle de la MB et MG.....	- 44 -
Figure 22: La coopération Mean-shift , approche flou.....	- 45 -
Figure 23 : schéma d'optimisation itératif.....	- 47 -
Figure 24 : Les étapes de coopération croissance de régions\contours.....	- 50 -
Figure 25 : Coopération hybride Floue\croissance de régions.....	- 52 -
Figure 26 : Approche hybride séquentielle\fusion\ rétroaction.....	- 55 -
Figure 27 : Différence entre IA et IAD.....	- 58 -
Figure 28 : Structure générale d'un agent qui interagit avec d'autres agents.....	- 60 -
Figure 29: Modèle d'agent cognitif.....	- 61 -
Figure 30 : modèle d'agent réactif.....	- 62 -
Figure 31 : Système Tableau noir (blackboard).....	- 65 -
Figure 32: Système Hiérarchique.....	- 66 -
Figure 33 : Communication par délégation.....	- 69 -
Figure 34 : la mauvaise interprétation des degrés d'appartenance du FCM.....	- 79 -
Figure 35: La partition de l'espace de représentation.....	- 82 -
Figure 36: influence des points aberrants sur les centres des classes.....	- 82 -
Figure 37 : influence des points ambigus sur les centres des classes.....	- 83 -
Figure 38 : les zones d'ambiguïté.....	- 84 -
Figure 39 : étapes de la coopération hybride de l'approche proposée.....	- 91 -
Figure 40: Le système multi-agents proposé.....	- 93 -
Figure 41 : Structure d'agent atomique.....	- 94 -
Figure 42 : Education d'un agent.....	- 94 -
Figure 43 : La hiérarchie des agents utilisés.....	- 97 -
Figure 44 : Processus de construction des images simulées.....	- 101 -
Figure 45 : Processus d'évaluation sur des images fantômes.....	- 102 -
Figure 46 : Deux régions A et B.....	- 103 -
Figure 47 : Recouvrement entre les deux régions A et B.....	- 103 -
Figure 48 : comparaison de l'image de référence et de l'image segmentée.....	- 105 -

Figure 49 : Comparaison des images segmentées par différentes approches	- 107 -
Figure 50 : Comparaison des images segmentées par différentes approches.....	- 108 -
Figure 51 : Images originales : coupes axiales (différentes pondérations D_p , $T1$, $T2$) ...	- 110 -
Figure 52 : Segmentation par FPCM	- 111 -
Figure 53 : Images originales : coupes sagittales (différentes pondérations D_p , $T1$, $T2$)-	- 112 -
Figure 54 : Segmentation par FPCM : coupes sagittales.....	- 113 -
Figure 55 : Images originales : coupes coronales.....	- 114 -
Figure 56 : Segmentation par FPCM : coupes coronales	- 115 -

Liste des tableaux

Tableau 1 : Comparaison entre méthodes de segmentation	-15-
Tableau 2 : Degrés d'appartenance générés par le FCM sur l'exemple	- 78 -
Tableau 3 : Comparaison des degrés d'appartenance générés par FCM et PCM.....	- 80 -
Tableau 7 : Propriétés des images utilisées.	- 109 -
Tableau 8 : Temps de segmentation en minutes pour un critère d'arrêt ($\epsilon = 0.05$).	- 116 -
Tableau 9 : Liste des modalités supportées par DICOM.	- 124 -
Tableau 10 : Différentes classes de la norme DICOM.....	- 125 -

Introduction générale

Malgré les avancées technologiques dans le domaine médical et en particulier dans l'imagerie médicale, l'étude du cerveau humain, que ce soit sur le plan anatomique ou fonctionnel, est un problème ardu et reste un sujet de recherche de forte actualité, du fait de l'évolution des matériels et des techniques d'imagerie, de la grande capacité de calcul des ordinateurs et de la mise en oeuvre de systèmes complexes de traitement de données. Une des modalités d'imagerie les plus couramment utilisées, à laquelle nous nous sommes intéressés dans le cadre de ce mémoire, est l'Imagerie par Résonance Magnétique (IRM), qui 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 et d'IRMf (IRM fonctionnelle).

Face à l'accroissement du nombre d'examens pratiqués en routine clinique (une image sur cinq est une image IRM), les systèmes de traitement informatiques ont un rôle essentiel à jouer afin de faciliter la tâche des praticiens. De tels systèmes ne se limitent pas à des rôles de visualisation des données, ils ont plutôt pour ambition de parvenir à aider le praticien dans ses choix de diagnostic, de lui signaler les risques pathologiques éventuels, et même de guider son geste chirurgical. Pour traiter ces images médicales, les ressources fournies par les ordinateurs sont sollicitées pour faciliter l'acquisition des images bidimensionnelles (2D) et tridimensionnelles (3D), ainsi que le prétraitement des images originales pour prélever l'information pertinente. L'une des opérations indispensables et primordiales pour tout traitement ultérieur est évidemment la segmentation qui consiste à délimiter les structures cérébrales (matière grise, matière blanche, liquide céphalorachidien) qui peuvent être utilisées dans plusieurs applications tel que la morphométrie (mesures des formes) pour permettre d'identifier, comprendre et suivre la progression des pathologies (*Alzheimer*, *schizophrénie*), la cartographie fonctionnelle et la visualisation.

Pour un diagnostic fiable, dans le domaine médical, la précision est importante. En termes d'analyse d'images, il est nécessaire que la segmentation soit précise. La segmentation des IRM cérébrales présente des particularités par rapport à d'autres domaines de la segmentation, comme celle des cartes routières, ou des visages. Ces particularités sont liées aux spécificités des objets à segmenter (l'anatomie du cerveau, le chevauchement entre matières...etc.) et au processus d'acquisition IRM. La plupart des images médicales contiennent plusieurs artefacts

qui rendent difficile la segmentation, ces artefacts (ou défauts) sont principalement dus aux bruits ; à l'inhomogénéité de la radio fréquence ; au patient lui-même à cause de ses mouvements pendant l'acquisition de l'image...etc. Les Images par Résonance Magnétique (IRM) sont particulièrement caractérisées par l'effet du volume partiel que l'on retrouve lorsqu'un pixel ayant un certain niveau de gris (cela est également le cas avec les voxel en 3D) correspond en réalité à un mélange de deux ou plusieurs tissus (les pixels sont appelés *mixels*), cet artefact existe principalement aux frontières entre tissus (MG\MB notamment). L'objectif de ce travail est justement de pallier tous les inconvénients en proposant de nouveaux outils de segmentation adaptés aux spécificités des images IRM cérébrales. Afin de rendre ces techniques plus robustes face aux différents artefacts, nous mettons l'accent sur le caractère coopératif en proposant d'introduire le paradigme multi-agents pour coordonner et organiser le processus de segmentation.

Dans ce travail on a essayé, de mettre en oeuvre les méthodes de segmentation d'image en se concentrant sur les méthodes non supervisées (FCM, PCM...). D'après l'étude détaillée des différentes méthodes de segmentation des IRM, on a décelé des inconvénients et des avantages pour chacune. Ce qui nous a permis d'affirmer qu'il n'existe pas de méthode de segmentation idéale malgré les améliorations apportées. Les méthodes de segmentation contours et régions, sont simples à mettre en oeuvre. Toutefois, l'une comme l'autre, ne sont utilisables que dans des contextes limités et demandent l'intégration d'informations *a priori* sur les zones recherchées ainsi que l'intervention d'un opérateur pour placer les germes initiaux.

Quelles que soient les régions d'intérêt recherchées, les différentes expériences et comparaisons présentées dans la littérature préfèrent les approches non supervisées par rapport aux approches supervisées trop dépendantes de l'opérateur [BAR 99] et nécessitent de créer une base d'apprentissage pour chaque image et pour chaque patient . C'est le point de vue que nous adoptons également. Parmi les méthodes statistiques (classification) présentées, nous nous sommes concentrés aux approches floues et possibilistes. Ces approches représentent en effet les principaux fondements théoriques utilisés pour manipuler des informations imprécises et incertaines, telles que les images IRM.

Malgré la diversité des méthodes de segmentation d'images IRM, nous avons remarqué qu'il n'existe pas une méthode de segmentation optimale, et chaque méthode donne un résultat satisfaisant dans un contexte particulier, ce qui nécessite la mise en oeuvre de la coopération de différentes méthodes, qui doit combiner plusieurs sources d'informations ou modalités de traitement pour accomplir une tâche donnée, et tirer parti, par exemple, des

complémentarités entre méthodes ou opérateurs et augmenter ainsi la robustesse du processus de segmentation. Notre approche coopère entre l'algorithme FCM (Fuzzy C-Means) dont la contrainte d'appartenance d'un individu à une classe est gérée d'une manière relative et l'algorithme possibiliste PCM (Possibilistic C-means) qui relâche cette contrainte reflétant ainsi de manière exacte la réalité de la distribution des individus. Afin de rendre l'algorithme plus robuste face aux imprécisions et aux données aberrantes, deux types de rejets ont été proposés : le rejet d'ambiguïté qui concerne les individus situés entre les frontières des différentes classes et le rejet d'aberrance concernant les individus dont les similarités par rapport à toutes les classes sont très éloignées.

Le mémoire est organisé en six chapitres principaux :

Le premier chapitre présente le cadre applicatif du travail. Il rappelle quelques notions d'anatomie du cerveau humain, les principes fondamentaux de la technique d'imagerie par résonance magnétique, où la problématique est posée d'une manière détaillée (effet du volume partiel, bruit,...).

Dans le deuxième chapitre on a présenté les différentes approches et stratégies généralement utilisées pour la segmentation des tissus cérébraux tout en évoquant les avantages et les inconvénients de chaque approche.

Le troisième chapitre décrit les méthodes coopératives de segmentation qui utilisent plusieurs sources d'informations pour tirer partie des avantages de chaque méthode.

Le quatrième chapitre présente le paradigme multi-agents, où on introduit pour cela quelques notions de base sur les systèmes multi-agents et sur la conception de systèmes dits de segmentation, tout en montrant comment ces notions peuvent être appliquées à la segmentation des IRM.

Le cinquième chapitre présente la description du système développé suivant les principes introduits aux chapitres trois et quatre, avec une justification des choix des paramètres utilisés et l'architecture multi-agents proposée.

Le sixième chapitre présente les résultats obtenus dans le cadre de cette étude et illustre le fonctionnement du système sur des images réelles et simulées.

La conclusion et les perspectives de ce travail seront présentées à la fin du mémoire.

CHAPITRE I : Éléments d'anatomie cérébrale et IRM.

Introduction

Ce chapitre a pour objectif de fixer le cadre applicatif que nous avons envisagé. Dans un premier temps nous présentons quelques éléments d'anatomie du système nerveux central, afin de préciser le vocabulaire et les notions qui seront utilisés le long de ce mémoire. Dans un second temps, nous présentons brièvement les principes physiques de l'IRM (l'imagerie par résonance magnétique) en insistant plus particulièrement sur les difficultés qui découlent de cette technique d'acquisition.

1. Quelques éléments d'anatomie cérébrale

1.1. Le cerveau :

« *Partie antérieure de l'encéphale formée des hémisphères cérébraux et des structures qui les unissent* ». Telle est la définition du cerveau dans le Petit Larousse. Le cerveau humain est l'étage le plus élevé dans la hiérarchie fonctionnelle du système nerveux central, son poids moyen varie entre 1400 à 1800 grammes. Il est placé dans la boîte crânienne mais n'est pas directement au contact de la cavité osseuse.

Le cerveau est constitué essentiellement de deux hémisphères, séparés par la scissure inter hémisphérique reliées par différentes structures telles que le corps calleux, le thalamus et l'hypothalamus. Le cerveau est composé de substance (ou matière) grise externe appelée cortex, de substance blanche sous-jacente et de structures profondes appelées noyaux gris centraux. Le cerveau baigne dans un liquide appelé liquide céphalo-rachidien [LAR 06].

1.2. Les principaux tissus cérébraux [LAR 06]

1.2.1. Le liquide céphalo-rachidien

Le liquide céphalo-rachidien ou cérébro-spinal (en anglais *cerebro-spinal fluid*) entoure le cerveau et remplit les ventricules cérébraux. Il permet de protéger le cerveau des chocs en jouant un rôle d'amortisseur, et remplit des fonctions importantes dans les échanges entre le sang et les tissus nerveux.

1.2.2. La matière grise

La matière grise constitue la partie des tissus du système nerveux central concentrant les corps cellulaires des neurones et des cellules gliales. Elle apparaît plus foncée que le reste du tissu car elle contient les noyaux des cellules.

Cette partie du tissu nerveux constitue le cœur du traitement de l'information nerveuse, on retrouve de la substance grise principalement au niveau du cortex cérébral, du cortex cérébelleux, dans les noyaux gris centraux (**Figure 1**), et dans les noyaux du tronc cérébral et à l'intérieur de la moëlle épinière




Figure 1: Structures anatomiques de la matière grise.

- **Le cortex** : Le cortex recouvre la totalité du cerveau. Sa surface est importante car il suit toutes les convolutions externes du cerveau, appelées sillons. Son épaisseur est d'environ 2 à 3 millimètres.
- **Les noyaux de base** : Les noyaux centraux, qui sont avec le cortex les seules structures de substance grise du cerveau, sont également formés de corps cellulaires neuroniques mais avec une densité moins importante que dans le cortex. Ils sont composés des noyaux du télencéphale, ces noyaux sont appelés les noyaux de base (ou corps strié), parmi eux, on distingue les noyaux caudés et les noyaux lenticulaires.
 - **Le noyau caudé** : En forme de virgule à grosse extrémité il est presque complètement enroulé autour du thalamus. Il longe à peu près dans toute son étendue le ventricule latérale. On lui distingue trois parties : la tête, le corps et la queue.

- **Noyaux lenticulaires** : Le noyau lenticulaire se situe en dehors du noyau caudé et du thalamus. Sa forme est celle d'une lentille biconvexe, triangulaire sur les coupes axiales et coronales. Le noyau lenticulaire se compose du putamen (externe), et du pallidum (interne).
- **Les noyaux du diencéphale**: parmi ces noyaux :
 - **Le thalamus** : le thalamus est une masse grise qui flanque la cavité du troisième ventricule, aboutissent toutes les sensations avant qu'elles soient projetées vers la conscience. Le thalamus est connecté aux centres moteurs et coordinateurs.
 - **L'hypothalamus** : l'hypothalamus est la paroi inférieure du troisième ventricule, se prolonge jusqu'à l'hypophyse. De petite dimension, il a la charge des équilibres physiologiques du corps. Les nouveaux atlas associent dorénavant le pallidum au groupe de noyaux gris du diencéphale [Bou 99].

1.2.3. La matière blanche

C'est la partie interne du cerveau, elle contient les liaisons entre les neurones. Les différents composants du cerveau sont présentés dans la **Figure 2** sur des coupes IRM équivalentes.




Figure 2: Coupes IRM du cerveau.

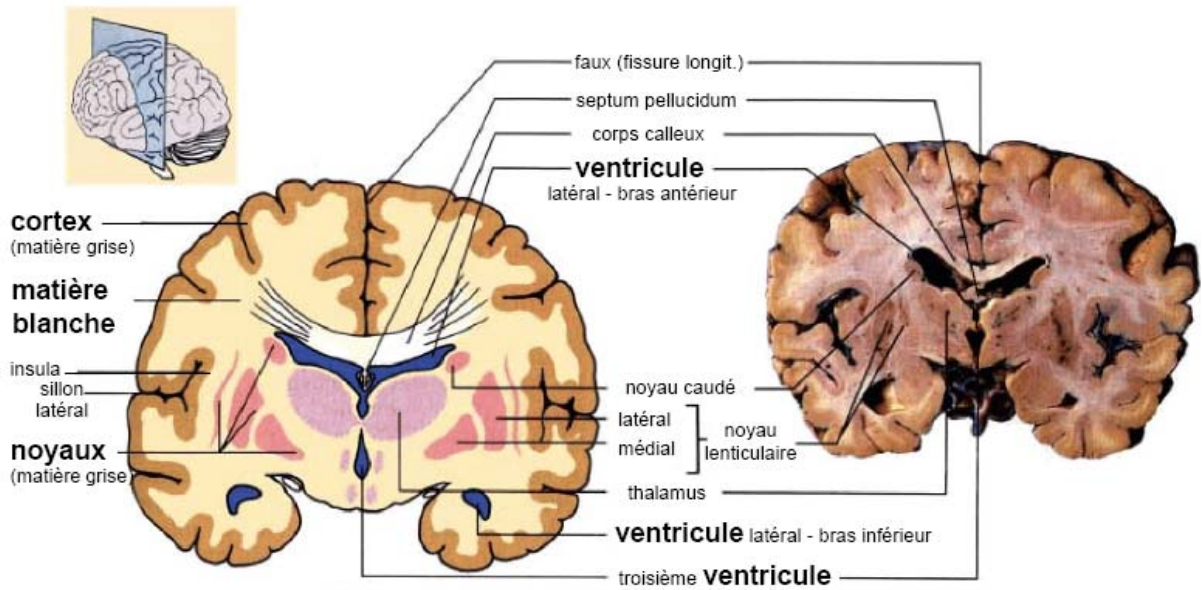


Figure 3: Différentes structures du cerveau.

2. Observation du cerveau

L'observation par des coupes en deux dimensions du cerveau peut être effectuée selon plusieurs angles de vue [FLO 90]. Ainsi, on distingue trois axes anatomiques pour réaliser les différentes coupes (Figure 4).

- **Coupes axiales**

Ces coupes correspondent quasiment à un plan horizontal. En imagerie par résonance magnétique, elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.

- **Coupes sagittales**

Ces coupes sont prises dans des plans parallèles au plan inter hémisphérique. Il s'agit des vues latérales du cerveau.

- **Coupes coronales**

Se sont des coupes perpendiculaires aux coupes axiales et sagittales.




Figure 4: Les trois axes de coupe pour la visualisation du cerveau.

3. IRM (Imagerie par Résonance Magnétique)

L'imagerie par résonance magnétique est une technique récente qui permet de produire des images anatomiques dans des plans multiples et qui peut fournir des informations sur la composition des tissus. La première acquisition d'IRM a été produite en 1973 par Lauterbur et Damadian. Cette technique a permis d'arriver à des avancées technologiques et scientifiques majeures notamment pour le dépistage des pathologies [BIT 90].



Figure 5 : Acquisition par IRM.

3.1. Principe général

L'IRM est une technique d'investigation très performante, parfaitement indolore et sans danger [BIT 90]. L'IRM n'utilise pas de rayons X, elle est basée sur le principe de la résonance magnétique des protons du corps humain au sein d'un champ électromagnétique. Ce dernier est créé par un aimant géant en forme de tunnel au sein duquel le patient est placé¹. Des ondes électromagnétiques provoquent une aimantation spécifique des noyaux d'hydrogène présents en proportions diverses dans les tissus selon leur teneur en eau. Le signal émis par les protons, lors de leur retour à leur état de base, est à l'origine de la création des images. Les images obtenues sont traitées par de puissants logiciels qui permettent de reconstruire les différentes coupes. Ces images sont visualisées sur un écran puis transformées en clichés radiographiques (Figure 6).

¹ www.clinique-radiographique.com

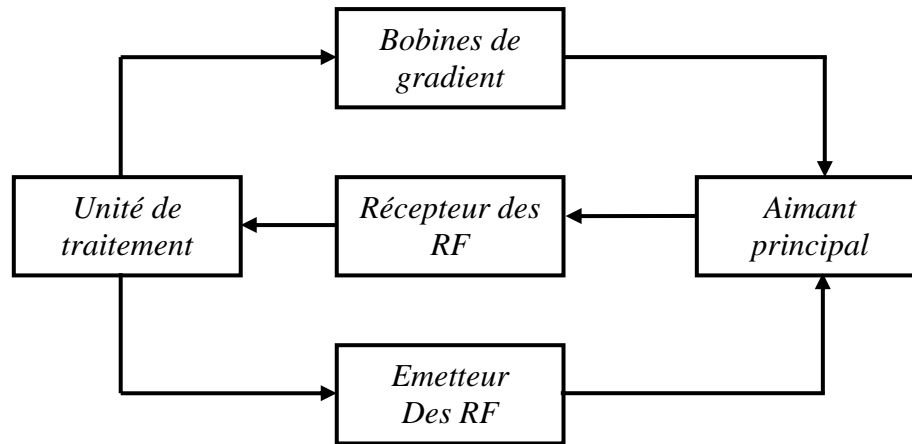


Figure 6 : Schéma fonctionnel de l'IRM.

3.2. Principe physique

Placé dans un champ magnétique statique $\mathbf{B}_0 = B_0 \mathbf{u}_z$, le moment magnétique d'un proton va tourner très rapidement autour de l'axe U_z en décrivant un cône de révolution. La fréquence avec laquelle se produit cette rotation, dite mouvement de précession, est donnée par la relation de Larmor : $f_0 = \gamma \frac{B_0}{2\pi}$ où γ est le rapport gyromagnétique du proton.

Ainsi, sous l'influence de \mathbf{B}_0 , les protons produisent un moment magnétique macroscopique (ou aimantation) d'équilibre \mathbf{M}_0 orienté dans la direction de \mathbf{B}_0 .

3.3. Phénomène de la résonance

La résonance est un transfert d'énergie entre deux systèmes oscillant à la même fréquence. Pour faire basculer un proton d'un état d'énergie E_1 à un état E_2 , il faut lui apporter une quantité d'énergie ΔE , reliée à la fréquence de résonance f_0 par la relation :

$$\Delta E = h \nu_0 = \frac{h \gamma B_0}{2\pi} \quad (1.1)$$

Lors d'une expérience RMN (*résonance magnétique nucléaire*), l'échantillon est soumis à une onde radiofréquence RF créée par un champ magnétique \mathbf{B}_1 , non colinéaire à \mathbf{B}_0 , et tournant à la fréquence f_0 . Les protons, qui étaient alignés selon \mathbf{B}_0 , reçoivent alors un apport d'énergie sous la forme d'une onde de pulsation égale à leur fréquence propre. Le vecteur aimantation macroscopique est basculé de sa position d'équilibre \mathbf{M}_0 vers une position \mathbf{M} tant que \mathbf{B}_1 dure, ce phénomène est appelé la résonance.

3.4. Relaxation et temps de relaxation

A l'arrêt de l'onde \mathbf{B}_1 , un signal dit de précession libre est enregistré. Il accompagne le retour à la position d'équilibre (en spirale) du vecteur \mathbf{M} . En particulier, le retour à l'équilibre

des projections de l'aimantation sur le vecteur U_z (aimantation longitudinale $M_L = (M \cdot u_z)u_z$) et sur le plan normal à ce vecteur (aimantation transversale $M_T = M - M_L$) est mesuré. Seule M_T participe au signal en générant un signal dans l'antenne réceptrice (**Figure 7**)




Figure 7: Phase de relaxation

Ces retours à l'équilibre suivent des cinétiques exponentielles indépendantes, qui dérivent des équations de Bloch :

$M_L(t) = M_0 - (M_0 - M_L(0))e^{-t/T_1}$ et $M_T(t) = M_T(0)e^{-t/T_2}$, où T_1 et T_2 sont respectivement les temps de relaxation longitudinale et transversale, dépendant des propriétés physico-chimiques des tissus.

3.5. Paramètres de séquence

Les paramètres de séquence sont les paramètres que le manipulateur fixe sur la console pour définir la séquence IRM. Ils permettent de contrôler l'influence des différents paramètres tissulaires T_1 , T_2 et densité de proton dans le signal et de moduler ainsi le contraste dans l'image.

3.5.1. Temps d'écho

Le signal de précession libre ne peut être enregistré directement après l'excitation (déphasage parasite induit par les gradients). C'est pourquoi il est acquis sous la forme d'un écho de spin ou de gradient. Par définition, le délai entre le milieu de l'impulsion d'excitation et le sommet de l'écho est appelé temps d'écho, il est noté TE . Dans la méthode d'écho de spin, les hétérogénéités de B_0 et les différences d'aimantation des tissus sont compensées, alors qu'elles ne le sont pas en écho de gradient. La courbe de décroissance est donc différente pour ces deux techniques.

3.5.2. Temps de répétition

L'image est constituée à partir de la répétition de la même séquence avec un gradient de phase G_p d'amplitude différente. Le temps qui sépare deux répétitions est appelé temps de répétition est noté TR . Le TR , comme le TE , est un facteur de contraste. S'il est suffisamment long, l'aimantation repousse tout le signal qui ne dépend pas de la vitesse d'aimantation (donc de T_1), mais essentiellement de la densité protonique. S'il est court, le système atteint après quelques répétitions un régime stationnaire et l'aimantation tend vers une valeur d'équilibre dépendant de la vitesse d'aimantation des tissus, et donc de leur T_1 . L'image révèle ainsi les différences de T_1 entre les tissus.

3.5.3. Angle de basculement

Si B_1 est orthogonal à B_0 , ce qui est généralement le cas, le phénomène de résonance magnétique bascule l'aimantation M selon un axe perpendiculaire au champ principal B_0 . Si M est basculé à 90° (excitation par une impulsion $\pi/2$), toute l'aimantation est dans le plan transversal et M_L est nulle. En cas de basculement d'un angle inférieur à 90° , seule une partie de l'aimantation est convertie en signal (M_T) et il persiste une aimantation M_L pouvant être utilisée pour une autre excitation. L'angle de basculement correspond donc à une énergie délivrée par le champ B_1 . Le signal S sera d'autant plus faible que cet angle sera petit. En régime stationnaire, l'angle de bascule α intervient dans le contraste de l'image et gouverne la réserve en aimantation. Pour des angles petits ($\alpha < 20^\circ$), la densité protonique est prépondérante. Plus α est grand, plus T_1 gouverne le contraste.




Figure 8: L'angle de basculement

3.6. Séquences IRM

En modifiant les valeurs des différents paramètres de séquence, une grande diversité de volumes variant par le contraste peuvent être acquis [Bos 03].

3.6.1. Image pondérée en densité de protons (ρ)

Pour un TR long (de l'ordre de 2s) et un TE court (de l'ordre de 20ms), la différence de densité protonique entre la substance grise et la substance blanche s'accroît. On obtient une séquence pondérée en densité de protons ρ , qui reflète la localisation et la concentration des noyaux d'hydrogène des différentes structures. Les tissus sont ordonnés par niveaux de gris croissants en matière blanche (MB), matière grise (MG) et liquide cérébro-spinal (LCS)

3.6.2. Image pondérée en T_2

Pour des TR longs (de l'ordre de 2s) et des TE longs (environ 90ms), la décroissance du signal domine la différence de densité protonique entre tissus, et le signal est suffisant pour réaliser une image dite pondérée en T_2 , où les tissus sont ordonnés par niveaux de gris croissants en MB, MG, LCS.

3.6.3. Image pondérée en T_1

Pour des TR courts (de l'ordre de 600ms), le contraste entre les tissus dépend essentiellement de leur vitesse d'aimantation, donc de T_1 . Pour des TE courts (environ 20ms), les différences de décroissance du signal entre les tissus n'ont pas le temps de s'exprimer, rendant le contraste indépendant de T_2 . Ainsi, on obtient une image pondérée en T_1 , où les tissus sont ordonnés par niveaux de gris croissants en LCS, MG, MB.




Figure 9: Les Séquences IRM, (a) : Image pondérée en ρ , (b) : Image pondérée en T_2
(c) : Image pondérée en T_1

3.7. Défauts des images IRM (artefacts)

Outre les trois paramètres principaux qui entrent en jeu dans la formation d'une image de résonance magnétique, un certain nombre d'autres facteurs viennent affecter la qualité des images. Les erreurs (artefacts) d'acquisition en IRM sont de natures différentes de celles observées dans d'autres domaines du traitement d'images.

On distingue essentiellement quatre effets: le bruit, le mouvement, les variations de champ et les effets de volume partiel [GER 99].

3.7.1. Bruit

Le bruit a des origines multiples, liées en partie au bruit de l'appareillage. Dans les images par résonance magnétique, l'objectif est d'augmenter le contraste entre les tissus tout en conservant une bonne résolution et un rapport signal/bruit élevé, ces caractéristiques sont cependant contradictoires et il est nécessaire de trouver un bon compromis entre résolution et bruit. Ainsi, on peut doubler la taille des pixels pour multiplier le rapport signal/bruit d'un facteur p , mais la résolution est divisée par deux. Le choix d'acquisition est donc un facteur déterminant.

3.7.2. Mouvement

Le mouvement peut provenir de plusieurs sources. Il peut être lié au métabolisme comme la circulation sanguine ou la respiration (déplacement chimique). Il peut également être lié au mouvement du patient pendant l'acquisition. Dans tous les cas, le mouvement diminue la qualité de l'image et pose des problèmes d'interprétation, les mouvements de la tête, sont responsables d'artefacts dans les IRM cérébrales.

3.7.3. Variations du champ magnétique (inhomogénéité RF)

Les variations de champ ont pour conséquence une variation des intensités d'un même tissu dans une direction quelconque de l'image. Ce phénomène est dû au fait que le champ magnétique n'est pas parfaitement homogène spatialement et temporellement pendant une acquisition. Il existe de plus des non-linéarités de gradient de champ magnétique.

Des approches ont été proposées pour corriger les inhomogénéités du champ magnétique dans le cadre de pré-traitements [SLE 98]. Les distorsions de champ sont également analysées en détail et corrigées dans [LAN 99].

3.7.4. Effets de volume partiel

Les effets de volume partiel sont directement liés au processus de numérisation du signal. Ainsi, si un pixel intersecte plusieurs objets, son niveau de gris sera une combinaison des niveaux de gris issus de chacun des objets traversés.

La prise en compte des effets de volumes partiels est nécessaire dans le cadre d'approches de segmentation dont l'objectif est d'effectuer des mesures sur les différents tissus. Cet artefact n'est pas très gênant pour le clinicien sauf dans des cas extrêmes, où le contraste entre différents tissus disparaît par exemple.




Figure 10 : L'inhomogénéité RF. (a) : Image affectée par une inhomogénéité RF, (b) : L'artefact RF isolé, (c) : Image sans artefact

Conclusion

Nous avons présenté dans ce chapitre les notions essentielles liées à l'anatomie du cerveau ainsi que les principes d'acquisition des images par résonance magnétique qui apporte une aide consistante en termes de diagnostic précoce et de caractérisation des tissus cérébraux.

On a remarqué qu'il y a des problèmes liés à l'anatomie du cerveau humain du fait qu'elle est compliquée dans le sens où elle présente de nombreuses structures cérébrales enchevêtrées, très diverses dans leurs formes et dans leurs compositions tissulaires. On peut se rendre compte des difficultés que rencontre le praticien (d'hétérogénéité des tissus cérébraux, bruit, l'effet du volume partiel, ...etc).

Pour analyser ces images médicales le médecin doit nécessairement connaître avec exactitude les changements survenus, de plus, il est parfois nécessaire d'analyser plusieurs images avant d'aboutir à la décision finale. Dans le domaine médical, la précision est importante, en termes d'analyse d'images, il est nécessaire que la segmentation soit précise.

CHAPITRE II : Méthodes de segmentation d'images

Introduction

La segmentation est un traitement de bas niveau qui consiste à créer une partition de l'image observée en un certain nombre de régions selon un critère déterminé (*couleur, texture, niveau de gris...*etc) qui pourront par la suite être traitées de manières différentes [GER 99].

Lorsque les informations traitées se composent de plusieurs images ou volumes obtenus sous différents paramètres d'acquisition, le traitement est appelé *multimodal* par opposition au traitement *monomodal*.

1. Applications et objectifs de la segmentation

Segmenter, ou délimiter les structures cérébrales est une étape fondamentale pour l'analyse d'images cérébrales. Les principales applications sont la morphométrie, la cartographie fonctionnelle et la visualisation.

- La morphométrie est la mesure quantitative des positions, formes et tailles de structures cérébrales, elle nécessite la segmentation préalable de ces structures. Elle peut permettre d'identifier, comprendre et suivre la progression des pathologies comme *L'autisme, l'Alzheimer* ou la *schizophrénie*.
- L'essentiel de l'activité fonctionnelle mesurable est situé dans le cortex dont la topologie est bidimensionnelle, la segmentation de la structure bidimensionnelle est alors nécessaire pour localiser les signaux, pour les cartographier et pour les visualiser.
- La visualisation des structures anatomiques (par exemple en chirurgie assistée), se fait naturellement à l'aide de la visualisation de leurs surfaces extérieures. Il est alors nécessaire de segmenter ces structures.

Toutes ces applications permettent de définir des objectifs et des propriétés primordiales pour un système de segmentation. L'automatisation complète est un objectif important, cependant la segmentation purement naturelle est extrêmement laborieuse (des chercheurs dans une étude sur la *schizophrénie* ont segmenté 50 images par an et par chercheur travaillant à temps plein) [GER 99]. Dans tous les cas, l'intervention humaine reste une source potentielle d'erreurs : au cours de longues séances d'interaction, l'opérateur humain change son comportement, la fatigue le fera commettre des erreurs et le résultat manque de fiabilité et de robustesse. Donc l'automatisation complète de la segmentation paraît indispensable pour le traitement des images médicales.

2. Spécificités de la segmentation de l'IRM cérébrale

La segmentation de l'IRM cérébrale présente des particularités par rapport à d'autres domaines d'applications de la segmentation, comme la segmentation des cartes routières, ou la segmentation des visages [Bos 03]. Ces particularités sont liées aux spécificités des objets à segmenter (l'anatomie du cerveau) et au processus d'acquisition IRM caractérisées par :

- **Information d'intensité insuffisante :** l'intensité observée sur des images IRM n'apporte qu'une information incomplète sur les structures anatomiques sous-jacentes. Plusieurs structures peuvent avoir la même intensité : en T_2 il n'y a pas de différence de contraste entre la MG et la MB. En T_1 , certaines structures, comme le corps calleux, n'ont pas de bords précisément délimités. Dans un autre exemple, l'intensité IRM lors de la transition entre la MG et la MB est complexe, et peut être variable. Une solution qui permet de palier à l'insuffisance des informations présentées dans l'image, est l'utilisation simultanée de plusieurs modalités.
- **Erreurs /artefacts d'acquisition :** les principaux artefacts apparaissant en IRM ont été présentés au paragraphe (cf. I.3.7). Lors de la segmentation, l'artefact le plus souvent cité est l'artefact d'inhomogénéité de la radio fréquence RF qui se manifeste par une variation spatialement lente de l'intensité des tissus sur l'image. La plupart des méthodes de segmentation prend en compte cet artefact, soit en l'éliminant par un prétraitement approprié, soit en le modélisant explicitement au cours de la segmentation.
- **Volume partiel :** le terme « *volume partiel* » est utilisé dans le milieu de l'imagerie médicale pour désigner les problèmes dus à l'échantillonnage (ou résolution) de l'image. En effet, si on considère une portion d'image à la frontière de deux tissus différents, l'échantillonnage donnera des pixels qui portent une information provenant de plusieurs pixels voisins, le terme « *volume partiel* » évoque une vision d'un pixel qui contiendrait un mélange de plusieurs tissus, le pixel à ce niveau est appelé « *mixel* ».

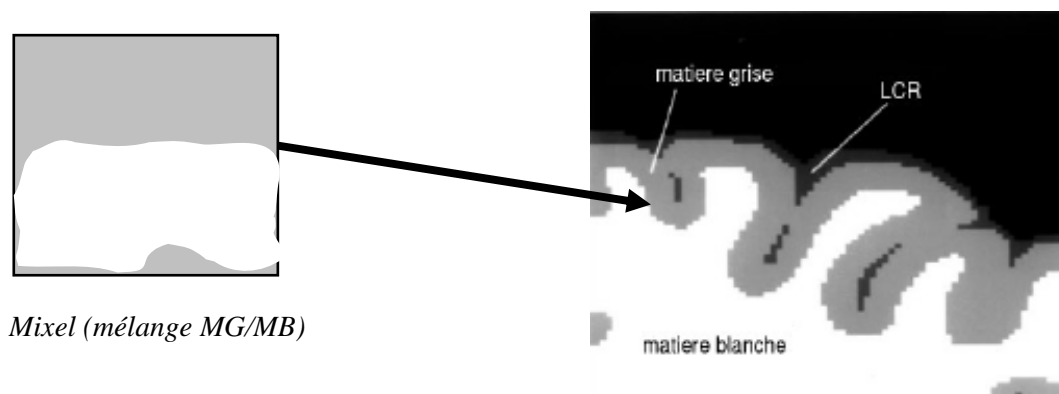


Figure 11 : Problème du volume partiel.

3. Les différentes méthodes de segmentation

3.1. Approches régions

Les approches régions visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou plusieurs critères. On recherche donc à rassembler les pixels par critères de similarité. Par la suite, nous nous intéressons plus particulièrement aux méthodes à base de seuillages, puis aux méthodes par croissance de régions et finalement aux méthodes fondées sur la morphologie mathématique.

3.1.1. Seuillages

Les méthodes de segmentation par seuillages visent à discriminer les individus (pixels) en fonction de leurs niveaux radiométriques (niveaux de gris). Elles supposent donc, de manière implicite, que l'intensité des structures est suffisamment discriminante pour permettre leur bonne séparation. Le plus souvent, les seuils sont déterminés à l'aide d'une analyse d'histogrammes.

Si ces méthodes sont simples à mettre en œuvre [BAR 99], on remarque cependant qu'elles nécessitent bien souvent des post-traitements. Ainsi, dans [BRU 93], où la problématique est de segmenter le cerveau sur des images pondérées en T_1 , un seuillage automatique fondé sur l'analyse de l'histogramme de l'image est utilisé pour discriminer le cerveau du fond de l'image. Cette méthode, testée sur des données simulées et réelles, est jugée, par les auteurs, simple, rapide et efficace. La segmentation de plusieurs volumes correspondant à un même sujet a montré des résultats satisfaisants.

Les méthodes de segmentation par seuillage sont des méthodes rapides et simples à mettre en œuvre. Néanmoins, elles échouent lorsque les régions de recherche sont insuffisamment contrastées, c'est-à-dire que les niveaux radiométriques des structures anatomiques se recouvrent. Le recouvrement des niveaux radiométriques entre les différentes structures

(volume partiel), limitant les performances de ces méthodes [BAR 99]. Toutefois, des solutions peuvent être mises en place. De plus, l'absence de prise en compte de contraintes de voisinage rend ces méthodes très sensibles aux bruits, les régions obtenues pouvant alors être sémantiquement peu cohérentes. Enfin, même si théoriquement les méthodes à base de seuillages peuvent s'appliquer à des volumes *multimodales*, elles n'exploitent en général qu'une seule pondération [KAP 90].

En dépit de leurs avantages, les méthodes de segmentation par seuillages ne sont pas adaptées pour segmenter les principales structures anatomiques. Leur utilisation nécessite, en particulier, la prise en compte d'informations locales, liées au voisinage d'un pixel.

3.1.2. Croissance de régions

Les algorithmes dits croissance de régions sont fondés sur l'agrégation progressive des pixels à partir d'un point initial appelé « germe », selon un critère. Les points voisins du germe sont successivement examinés. S'ils vérifient le critère d'agrégation, ils sont inclus à la région et deviennent à leur tour un germe. Dans le cas contraire, ils sont rejetés. Le critère est le plus souvent un critère local basé sur les niveaux radiométriques des pixels.

Dans [THI 97], Thiran *et al.* proposent une méthode de croissance de régions pour la segmentation du cerveau à partir des images IRM tridimensionnelles. La segmentation obtenue permet alors des rendus des surfaces cérébrales. Dans [SCH 01], le ventricule latéral et le troisième ventricule sont segmentés par croissance de régions et morphologie mathématique. La croissance de régions est guidée par des connaissances anatomiques *a priori* sur le système ventriculaire.

Tout comme les méthodes à base de seuillages, les segmentations par croissance de régions sont simples à mettre en oeuvre, mais parfois coûteuses en temps de calcul. Leur avantage réside dans la prise en compte des informations contextuelles par le mécanisme de croissance et dans la possibilité d'introduire des informations de plus haut-niveau. Néanmoins, leur inconvénient est lié à la disposition des germes initiaux. En effet, celle-ci nécessite l'intervention d'un opérateur. Enfin, nous notons leur utilisation restreinte au contexte monomodal [BAR 99].




Figure 12 : Image IRM segmentée par une approche région.

3.1.3. Morphologie mathématique

La morphologie mathématique est une branche des mathématiques fondée sur l'étude des ensembles permettant d'analyser les structures géométriques. Ses bases théoriques ont été établies par Matherons [MAT 65] et Serra [SER 82].

Les outils de base de la morphologie mathématique (érosion, dilatation, fermeture, ouverture. . .) se retrouvent fréquemment dans des méthodes de segmentation de l'enveloppe cérébrale. Ainsi dans [BRU 93], Brumer utilise des érosions, dilatations et étiquetages en composantes connexes à la suite de seuillages afin de déconnecter les structures non cerveau de la structure cerveau et d'affiner le masque initial.

Cette méthode est reprise dans [GER 98] en ajoutant quelques opérations morphologiques de façon à garantir une meilleure robustesse aux variations anatomiques et des acquisitions.

Toujours dans [GER 98], Géraud propose, à la suite de la segmentation du cerveau, de coupler seuillages et morphologie mathématique pour segmenter successivement le liquide céphalo-rachidien (ventricules et liquide des sillons) et la matière grise (cortex et noyaux de gris centraux) sur des images pondérées en T_1 . Les résultats obtenus sont jugés très corrects par l'auteur. Il modère toutefois ses propos du fait de la dépendance successive des segmentations et de la nécessité des connaissances des niveaux radiométriques pour la détermination des seuils.

La morphologie mathématique est rarement utilisée seule pour segmenter les structures cérébrales [BAR 00] mais fait généralement partie d'une chaîne de traitements plus complexe.

3.2. Approches contours

Contrairement aux approches régions, qui cherchent à former des zones homogènes, les approches contours travaillent sur les discontinuités des images afin de déterminer les contours des régions. Dans la suite, nous nous intéressons plus particulièrement aux méthodes dérivatives et aux méthodes fondées sur les modèles déformables.

3.2.1. Méthodes dérivatives

Les méthodes dérivatives permettent de détecter de manière simple les ruptures dans une image ou un volume. Les contours (ou surfaces en 3D) sont assimilés à des points de forts gradients ou de dérivées secondes nulles. On retrouvera alors des opérateurs tels que les filtres de Roberts [ROB 65], de Sobel [SOB 78] ou de Prewitt [PRE 70].

Parmi la diversité des opérateurs, celui de Marr-Hildreth [MAH 80] qui fournit des contours fermés. Dans [BOM 90], Boman *et al.* utilisent une approximation de cet opérateur dans un processus de segmentation. Les régions définies à partir des contours sont ensuite manuellement étiquetées. Les structures cérébrales recherchées sont alors la peau, le cerveau et le système ventriculaire. Malgré une bonne détection de la peau et du système ventriculaire, certains contours obtenus se trouvent décalés par rapport à la réalité anatomique. Dans ce cas particulier, une fermeture morphologique est recommandée.

Les méthodes dérivatives, employées pour la segmentation des images IRM cérébrales, sont relativement peu nombreuses dans la littérature. Bien que rapides et ne nécessitant pas d'apport d'information *a priori*, elles ne permettent pas, en général, d'obtenir des contours fermés.

Elles sont en effet très sensibles aux bruits et à la dérive du champ radiofréquence. Leur efficacité repose sur l'existence de contraste entre les structures recherchées. Si ceux-ci existent effectivement au niveau de la peau ou du système ventriculaire, ils sont beaucoup moins importants au niveau de la transition matière blanche - matière grise ou encore au niveau du liquide céphalo-rachidien. Enfin, ces méthodes fournissent fréquemment de la sous-segmentation ou de la sur-segmentation [DEL 91].




Figure 13 : Segmentation, approche contour. (a) : image IRM originale, (b) : image segmentée (approche contour)

3.2.2. Modèles déformables

Les algorithmes de segmentation fondés sur les modèles déformables dérivent des méthodes de contours dynamiques introduites par Terzopoulos [KAS 88]. Ils ont l'avantage, par rapport aux méthodes dérivatives, de fournir des contours ou surfaces fermés [GER 99]. Le principe de base est de faire évoluer un objet d'une position initiale vers une position d'équilibre par la minimisation itérative d'une fonctionnelle.




Figure 14 : Segmentation par modèle déformable. (a) : Image originale, (b) : Cerveau isolé

Cette dernière permet de prendre en compte, par l'intermédiaire de forces externes et internes, des informations *a priori* sur la forme de l'objet à détecter.

Dans [BAI 01], un modèle déformable est utilisé pour la segmentation du cerveau (matière blanche et matière grise). La méthode s'avère efficace même lorsque l'initialisation est

éloignée de la surface optimale. Sur des données réelles, l'algorithme n'a échoué que lorsque le liquide céphalo-rachidien est trop fin.

Les méthodes de segmentation par modèles déformables s'avèrent efficaces pour la segmentation de structures anatomiques particulières. Elles permettent en effet de s'adapter à la forme complexe des structures grâce à l'enrichissement des contraintes de déformation. Cependant, ces méthodes restent relativement sensibles à leur initialisation. Face à ce problème, les auteurs tendent à inclure des procédures d'initialisation automatique de façon à réduire l'influence des opérateurs et augmenter la reproductibilité des résultats. De plus, nous notons leur utilisation restreinte au contexte monomodal [GER 99].

3.3. Segmentation par classification

La classification des tissus cérébraux (principalement le liquide cérébro-spinal, la matière blanche et la matière grise) est un problème abondamment abordé dans la littérature [BEZ 93], dans cette partie nous proposons d'explicitier quelques méthodes supervisées, puis nous étudions quelques algorithmes non supervisés en insistant tout particulièrement sur les algorithmes de classification flous.

3.3.1. Méthodes supervisées

Les méthodes supervisées nécessitent un ensemble d'images ou de régions d'intérêt dans l'image déjà étiquetées. Les données à analyser $X = \{x_j \in \mathbf{R}^p, 1 \leq j \leq N\}$, où X_j est un vecteur forme représentant le pixel j , sont donc décomposées en un ensemble d'apprentissage et un ensemble de test. Les données segmentées de l'ensemble d'apprentissage proviennent d'un étiquetage manuel des images ou des régions d'intérêt en C classes de tissus $C_1 \dots C_C$ par un ou plusieurs experts (radiologues). Chaque classe C_i se voit donc affecter un ensemble d'apprentissage E_i , et les données de l'ensemble de test sont segmentées en fonction des E_i .

Puisque la structure anatomique d'un cerveau est différente d'un patient à l'autre, l'étiquetage doit être renouvelé pour chaque patient ou groupe de patients, ce qui représente une tâche longue et fastidieuse pour les spécialistes.

3.3.1.1. Segmentation bayésienne

La segmentation bayésienne consiste à calculer, pour chaque vecteur forme X_j , la probabilité conditionnelle $P(C_i/x_j)$ pour chacune des C classes (C_1, \dots, C_C) à l'aide de la règle de Bayes :

$$(\forall i \in \{1..C\}) P(C_i | \mathbf{x}_j) = \frac{P(C_i) \cdot P(\mathbf{x}_j | C_i)}{\sum_{k=1}^C P(C_k) \cdot P(\mathbf{x}_j | C_k)} \quad (2.1)$$

Les lois $P(C_i)$ et $P(\mathbf{x}_j | C_i)$, donnant la probabilité de trouver un individu de classe C_i parmi des individus de vecteurs forme \mathbf{X}_j , sont souvent inconnues. Si la probabilité $P(C_i)$ peut être assez facilement déduite de la base d'apprentissage, la recherche de la loi $P(\mathbf{x}_j | C_i)$ est plus délicate, elle peut être effectuée par estimation.

a) Segmentation bayésienne paramétrique

L'intensité d'un pixel est ici considérée comme une combinaison linéaire de probabilités d'appartenance attachées à chaque classe (modèle de mélange). La probabilité conditionnelle $P(\mathbf{x}_j | C_i)$ est modélisée par une fonction dépendant d'un vecteur de paramètre \mathbf{q} .

Le problème est alors pour chaque classe C_i d'estimer le meilleur paramètre \mathbf{q} connaissant l'ensemble d'apprentissage E_i de cette classe. De nombreux estimateurs peuvent être utilisés dans ce but, mais le plus fréquemment rencontré est l'estimateur de maximum de vraisemblance. Celui-ci détermine la valeur de \mathbf{q} qui maximise :

$$p(E_i | \theta) = \prod_{k=1}^{|E_i|} p(x_k | c_i, ?) \quad (2.2)$$




Figure 15 : Segmentation par méthode bayésienne.

Cette approche convertit le problème difficile de recherche de fonction en un problème plus simple d'estimation de paramètres en imposant une forme particulière à la fonction (souvent gaussienne) [BAR 99]. Cette restriction peut cependant introduire des erreurs de classification, puisque les données ne sont que rarement conformes à des distributions paramétriques. Selon [BEZ 93], les hypothèses de ce type sont mal adaptées à la segmentation d'images médicales, IRM en particulier, où l'intensité d'un pixel ne peut être dérivée d'une combinaison linéaire de probabilités distinctes attachées aux classes.

Ainsi, malgré le consensus général qui affirme que chaque classe de tissu peut être modélisée par une loi gaussienne en IRM [GER 98], nous remarquerons que les différents défauts de l'image (hétérogénéité de champ en particulier) rendent cette approximation hasardeuse lorsqu'il s'agit d'effectuer des mesures précises de volume.

b) Segmentation bayésienne non paramétrique

Dans ce type d'approche, les probabilités conditionnelles $P(x_j|C_i)$ sont supposées quelconques. La forme non paramétrique doit permettre de rendre compte le plus fidèlement possible de la réelle distribution statistique des niveaux de gris dans l'image. Une méthode souvent utilisée consiste en la modélisation des probabilités conditionnelles par des fenêtres de Parzen [DUD 73]. Pour chaque classe C_i d'ensemble d'apprentissage $E_i = \{n_j^i\}$, la loi $P(x_j|C_i)$ est obtenue en centrant une gaussienne de largeur s faible autour de chaque vecteur d'entraînement

$$p(x_j | c_i) = \frac{1}{|E_i|} \sum_{k=1}^{|E_i|} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x_j - n_j^i)^2}{2\sigma^2}} \tag{2.3}$$

Ainsi, Held [HEL 97] et al. intègrent cette modélisation dans un schéma de segmentation d'images IRM pondérées en T_2 et en densité de protons. Velthuizen et al. [VEL 93] proposent un schéma d'initialisation d'un algorithme de classification fondé sur cette méthode.

3.3.1.2. Segmentation Markovienne

La théorie des champs de Markov permet d'associer le processus de segmentation à la minimisation d'une fonction d'énergie définie sur l'image à segmenter. Grâce à l'introduction de notions de voisinages entre pixels, cette approche permet d'envisager la recherche de modèles locaux de distributions selon un principe équivalent localement à celui de la classification bayésienne.

a) Eléments théoriques [Coc 95]

Les approches utilisant les champs de Markov sont fondées sur une théorie utilisant des notions de voisinages et de cliques que nous rappelons ici.

Une image de taille $N \times N$ est définie par l'ensemble de ses pixels P_{ij} et noté :

$$I = \{p_{ij} = (i, j), i \leq 1, j \leq n\} \tag{2.4}$$

A chaque pixel est associée une variable aléatoire A_j dont les valeurs appartiennent à un ensemble Ω donné. L'image est considérée comme un vecteur aléatoire $A = (A_i, i \in I)$ et

$a = (a_i, i \in I)$ est une réalisation de A . Un système de voisinage V est défini sur cette image de la façon suivante : tout voisinage V vérifie deux propriétés qui sont :

- Un pixel n'appartient pas à son voisinage.
- La relation de voisinage est symétrique : si un pixel S appartient au voisinage d'un pixel T alors T appartient au voisinage v_s de S .

La définition d'un champ markovien associe un champ aléatoire A à un système de voisinage V à la condition suivante (la condition de positivité étant nécessaire seulement pour que le champ soit un champ de *Gibbs*) :

$$\begin{cases} P(a) > 0 \\ P(a_i | a_j, j \in I - \{i\}) = P(a_i | a_j, j \in v_i) \end{cases} \quad (2.5)$$

Ce qui revient à considérer que l'influence d'un pixel est limitée à une zone locale de l'image, située autour de ce pixel.

La définition des cliques est nécessaire pour la formalisation. Une clique est un ensemble de pixels tel que deux pixels quelconques de l'ensemble sont voisins au sens de V .

- **Mesure de Gibbs :**

D'après le théorème d'Hammersley-Clifford un champ aléatoire A associé au système de voisinage V est un champ markovien si et seulement si sa distribution de probabilité $p(A = a)$ est une mesure de Gibbs :

$$\forall A \in \Omega^{N \times N}, P(a) = \frac{\exp(-u(a))}{\sum_{a \in \Omega^{N \times N}} \exp(-u(a))} \quad (2.6)$$

où U est une fonction d'énergie correspondant à la somme des potentiels de chaque clique de l'image.

b) Application à la segmentation d'images

Puisque les champs de Markov prennent en compte les contraintes spatiales dans la segmentation, les modalités anatomiques se prêtent tout particulièrement à ce type de méthode. Citons par exemple Held *et al.* [HEL 97] qui segmentent des images IRM pondérées en T_2 et densité de protons à l'aide d'un champ de Markov modifié permettant d'estimer les hétérogénéités dans l'image simultanément à la segmentation, ou Jaggi *et al.* [JAG 97] qui s'affranchissent des effets de volume partiel en IRM en estimant les coefficients d'un modèle de mélange à 5 classes (LCS, MG, MB, MB/MG et LCS/MG) à l'aide d'un champ de Markov.

3.3.1.3. Algorithme des k plus proches voisins

L'algorithme des k plus proches voisins (kppv) est une méthode supervisée de classification introduite dans [DUD 73] qui est largement utilisée en classification d'images. Elle repose sur un principe simple et intuitif de regroupement d'individus en fonction de leur voisinage.

a) Principe

Etant donnés les ensembles d'apprentissage E_i , de cardinaux assez grands, la distance d'un vecteur non étiqueté X_j à chacun des vecteurs des E_i est calculée. La probabilité *a posteriori* d'appartenance de X_j à une classe est estimée d'après la fréquence des classes présentes parmi les k plus proches voisins de ce vecteur. La règle de décision classique consiste à affecter X_j à la classe la plus représentée parmi ses k plus proches voisins. Seuls la distance et k doivent être déterminés. La première détermine la forme du voisinage de chaque vecteur X_j , et le choix de k est arrêté lorsqu'une valeur supérieure ne modifie pas la classification.

b) Application à la segmentation d'images

Cet algorithme est couramment utilisé en caractérisation des tissus cérébraux. Par exemple, dans [VIN 98], les auteurs choisissent k égal à 20 et 40 pour une classification respectivement bi- et tridimensionnelle, alors que Clarke *et al.* [CLA 93] optent pour la valeur 7. Ces mêmes auteurs utilisent cet algorithme comme méthode de référence car elle s'avère être selon eux, la plus stable en termes de variabilité. Toutefois, dans des articles postérieurs à cette étude, des chercheurs de la même équipe précisent, dans la partie concernant la sélection de l'ensemble d'apprentissage, que si les résultats obtenus sont visiblement anatomiquement incorrects, un nouvel ensemble d'apprentissage doit être choisi jusqu'à obtention d'une bonne segmentation [VEL 95]. Le choix de l'ensemble d'apprentissage n'est pas donc évident.

De plus, la méthode est pénalisée par un temps de calcul élevé sur des architectures non parallèles, puisqu'il faut calculer pour chaque pixel de l'image n'appartenant pas à l'ensemble E_i la distance à chacun des pixels de l'ensemble d'apprentissage, puis les ordonner avant de sélectionner la classe la plus représentative. Vinitski *et al.* [VIN 99] ont proposé de réduire le temps de calcul en excluant les points "redondants" et "marginiaux" de l'ensemble d'apprentissage de chaque classe. Ôter un élément redondant de l'ensemble d'apprentissage d'une classe de tissu n'est pas nécessairement judicieux, puisque cela revient à diminuer le pouvoir d'attraction de cet amas et à augmenter ainsi le risque de mauvaises classifications.

Remarque :

Il y a des auteurs qui considèrent la méthode des KPPV comme méthode non supervisée.

3.3.1.4. Réseaux de Neurones

a) Description formelle d'un réseau de neurones

- *Architecture d'un réseau*

Un réseau de neurones est un réseau d'unités élémentaires (les nœuds) interconnectées, à fonctions d'activation linéaires ou non linéaires. Ces nœuds sont regroupés pour les réseaux multicouches en au moins deux sous-ensembles de neurones : un sous-ensemble d'entrée, un autre de sortie et éventuellement un ensemble de neurones cachés. De nombreux modèles de réseaux existent (réseaux de Hopfield, perceptrons multicouches,...) [MAG 99], les différents nœuds étant complètement ou partiellement interconnectés aux autres. L'ensemble des liens convergeant vers un nœud constitue les connexions entrantes du nœud. Ceux qui divergent vers d'autres nœuds sont les connexions sortantes. A chaque connexion entre des nœuds i et j , est associé un poids W_{ij} représentant la force de l'influence du nœud i sur le nœud j . L'ensemble des poids est regroupé dans un vecteur de poids W . Un vecteur de scalaires A présenté à tous les nœuds d'entrée est appelé exemple. A cet exemple sont aussi associées les valeurs y (le vecteur de sortie) que l'on désire apprendre. Les poids des connexions sont éventuellement modifiés au cours d'un cycle d'apprentissage (**Figure 16**).

Modifier la sortie des nœuds à partir de leurs entrées consiste tout d'abord à calculer l'activation présente à l'entrée du nœud puis à calculer la sortie du nœud suivant la fonction d'activation qu'elle possède. Un réseau de neurones peut ainsi être défini pour chaque nœud par quatre éléments :

- La nature de ses entrées, qui peuvent être binaires ou réelles.
- La fonction d'entrée totale e , qui définit le pré-traitement $e(a)$ effectué sur les entrées. Généralement, e est une combinaison linéaire des entrées pondérées par les poids des connexions entrantes.
- La fonction d'activation f du nœud qui définit son état de sortie en fonction de la valeur de e . Toute fonction croissante et impaire convient et la fonction sigmoïde est souvent utilisée. La valeur de f en $e(a)$ est redirigée vers l'extérieur ou vers d'autres nœuds où elle contribue à calculer leur état d'activation.
- La nature de ses sorties, qui peuvent être binaires ou réelles.

Deux éléments sont enfin nécessaires au bon fonctionnement du réseau : une fonction de coût et un algorithme d'apprentissage.

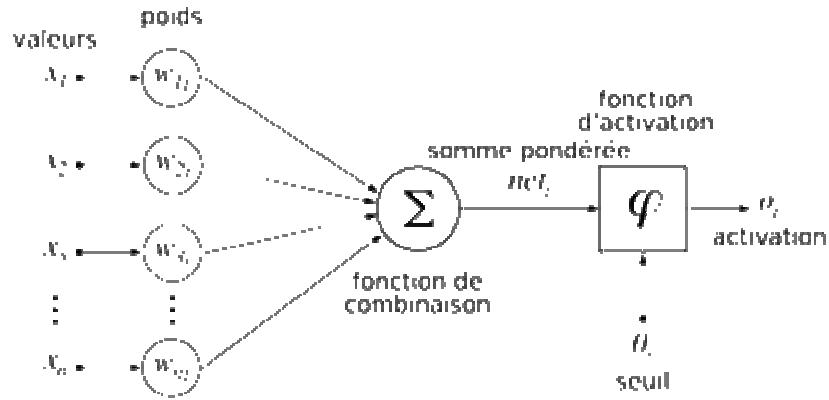


Figure 16 : Structure d'un neurone artificiel.

- *Apprentissage*

L'apprentissage consiste en l'adaptation des paramètres du réseau de neurones pour donner une réponse désirée à une entrée donnée. La méthode classique en apprentissage supervisé consiste à se procurer un ensemble d'exemples entrées/sorties $\{(a^k, y^k), k \in K\}$. La fonction calculée par le réseau est alors décrite sous une forme paramétrique, $f(a^k, w)$, et désigne la sortie du réseau quand le vecteur a^k est présenté en entrée et que le réseau utilise le vecteur de poids w . Une distance d sur l'espace vectoriel de sortie est également choisie et permet de mesurer l'erreur commise $d(f(a^k, w), y^k)$ en un point par le réseau. Le but de l'apprentissage est alors de trouver la valeur de w qui minimise l'erreur totale commise par le réseau pour l'ensemble $\{(a^k, y^k), k \in K\}$.

- *Généralisation*

Enfin, l'étape suivante consiste à généraliser la représentation construite lors de la phase d'apprentissage pour des données quelconques. Elle consiste en une mesure des performances du réseau de neurones sur des données représentatives du problème non apprises. L'erreur de généralisation ainsi mesurée dépend essentiellement du nombre d'exemples utilisés pour l'apprentissage, de la complexité du problème sous-jacent et de l'architecture du réseau.

b) Application à la segmentation des tissus

Magnotta *et al.* [MAG 99] ont utilisé un réseau de neurones pour segmenter certaines structures fines de matière grise (putamen, noyau caudé) et blanches (corps calleux) sur des images IRM. L'apprentissage a été effectué par une segmentation manuelle sur 2/3 des images disponibles, le tiers restant étant segmenté par le réseau entraîné. La comparaison à une segmentation manuelle par deux praticiens a révélé une adéquation entre les deux résultats avec un taux de réussite moyen de 88%. Dans le même contexte, Cagnoni *et al.* [CAG 93] ont classifié les différents tissus cérébraux en utilisant une architecture neuronale

sur des images IRM multi-échos. Enfin, Clarke *et al.* [CLA 93] ont analysé les résultats d'un réseau de neurones pour la caractérisation de tissus (MB, MG, LCS, muscle, graisse, fond) en IRM, avec une base d'entraînement constituée à partir d'images pondérées en T_1 , T_2 et en densité de protons. Les auteurs ont démontré que les réseaux de neurones sont très sensibles à la base d'entraînement proposée à l'entrée du réseau. Si le réseau de neurones doit être utilisé, il impose une intervention constante de l'opérateur qui doit sélectionner pour chaque image des données d'entraînement pertinentes.

3.3.2. Méthodes non supervisées (Automatiques)

L'intérêt des méthodes non supervisées est qu'elles ne nécessitent aucune base d'apprentissage et aucune tâche préalable d'étiquetage manuel. La seule intervention de l'expert se situe à la fin du processus pour identifier les classes calculées avec les classes biologiques [BAR 99].

Ici on va décrire les algorithmes qui nous ont paru utiles pour notre étude. La présentation détaillée d'une de ces classes de méthodes, les algorithmes de classification, permettra dans les chapitres suivants d'introduire la solution que nous avons adoptée.

o Génération de fonctions d'appartenance

Notons $X=(x_j, j=1..N)$ l'ensemble des vecteurs forme de \mathbf{R}^p , avec $x_j=[x_{j1},x_{j2},\dots,x_{jp}]^T$, et $B=(b_1,\dots,b_c)$ un ensemble de vecteurs prototypes inconnus, où b_i caractérise la classe i . La génération de fonctions d'appartenance consiste à construire automatiquement des fonctions permettant d'affecter chaque x_j à une ou plusieurs classes selon certains critères. Nous proposons tout d'abord de décrire les algorithmes de classification, qui représentent une classe importante de ces méthodes. Ceux-ci déterminent B et recherchent un regroupement des vecteurs x_j en C classes par minimisation itérative d'une fonctionnelle. Suivant que les vecteurs forme sont assignés à une unique classe ou à plusieurs, les algorithmes de classification sont non flous ou flous (fuzzy).

3.3.2.1. Algorithmes de classification non flous

Dans la méthode HCM (Hard Clustering Means) [BEZ 81], un élément de X est attribué à une classe et une seule parmi les C proposées. Dans ce cas, la fonctionnelle à minimiser est :

$$J(B,U,X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij} d^2(x_j, b_i) \quad (2.7)$$

et les solutions au problème s'écrivent :

$$u_{ij} = \begin{cases} 1 & \text{ssi } d^2(\mathbf{x}_j, \mathbf{b}_i) < d^2(\mathbf{x}_j, \mathbf{b}_k) \forall k \neq i \\ 0 & \text{sinon} \end{cases} \quad (2.8)$$

$$\mathbf{b}_i = \frac{\sum_{j=1}^N u_{ij} \mathbf{x}_j}{\sum_{j=1}^N u_{ij}} \quad (2.9)$$

La classification des éléments de \mathbf{X} s'effectue de manière itérative en alternant l'étape de classification (2.8) et l'étape de mise à jour des centres (2.9), jusqu'à stabilisation de la segmentation ou de la fonction objectif. Dans une variante nommée ILSC (Iterative Least Squares Clustering) [VEL 95], les vecteurs \mathbf{b}_i sont recalculés à chaque ajout d'un élément dans une classe. Ces auteurs rapportent un bon taux de reconnaissance des tissus cérébraux en IRM, mais cette modification entraîne à la fois un temps de calcul plus long et une dépendance de la partition finale à l'ordre de parcours de l'image [PEN 99].

Dans une méthode comme HCM, les éléments sont classés de façon certaine comme appartenant à une classe et une seule. Quelle que soit la modalité d'imagerie, cette assertion ne reflète pas la réalité physique de l'échantillon étudié (bruit, volume partiel, hétérogénéité de champ) [BAR99]. Les méthodes présentées dans les paragraphes suivants permettent d'obtenir une segmentation floue qui prend en compte ces aspects imprécis et incertains.

3.3.2.2. Algorithme des C-moyennes floues (FCM)

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

a) Présentation de l'algorithme FCM

- Formulation du problème

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

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

$$0 < \sum_{j=1}^N u_{ij} < N \quad (2.10)$$

$$(\forall j \in \{1..N\}) \sum_{i=1}^C u_{ij} = 1 \quad (2.11)$$

Bezdek a montré [BEZ 81] que le problème de partition de X en C classes floues pouvait être formulé comme la minimisation d'une fonctionnelle $J(B, U, X)$ définie par :

$$J(B, U, X) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i) \quad (2.12)$$

sous les contraintes (2.10) et (2.11) où :

- $m > 1$ est un paramètre contrôlant le degré de flou de la partition résultante.
- $(\mathbf{x}_j, \mathbf{b}_i) \rightarrow d^2(\mathbf{x}_j, \mathbf{b}_i)$ est une distance du vecteur \mathbf{x}_j au prototype \mathbf{b}_i .
- Obtention de U et B

Les solutions au problème de minimisation précédent sont obtenues par une méthode lagrangienne. Plus précisément, si $H(\mathbf{x}_j)$ est défini pour chaque vecteur \mathbf{x}_j par :

$$H(\mathbf{x}_j) = \sum_{i=1}^C u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i) - \alpha \left(\sum_{i=1}^C u_{ij} - 1 \right), \quad \alpha > 0,$$

l'annulation des dérivées partielles par rapport à u_{ij} et α donne :

$$\frac{\partial H(\mathbf{x}_j)}{\partial \alpha} = 0 \quad \text{et} \quad \frac{\partial H(\mathbf{x}_j)}{\partial u_{ij}} = m \cdot u_{ij}^{m-1} \cdot d^2(\mathbf{x}_j, \mathbf{b}_i) - \alpha = 0,$$

de telle sorte que, si $d^2(\mathbf{x}_j, \mathbf{b}_i) \neq 0$:

$$u_{ij} = \left(\frac{\alpha}{m \cdot d^2(\mathbf{x}_j, \mathbf{b}_i)} \right)^{\frac{1}{m-1}}$$

avec

$$\sum_{i=1}^C u_{ij} = \left(\frac{\alpha}{m} \right)^{\frac{1}{m-1}} \sum_{i=1}^C \left(\frac{1}{d^2(\mathbf{x}_j, \mathbf{b}_i)} \right)^{\frac{1}{m-1}} = 1$$

et finalement

$$u_{ij} = \left[\sum_{k=1}^C \left(\frac{d^2(\mathbf{x}_j, \mathbf{b}_i)}{d^2(\mathbf{x}_j, \mathbf{b}_k)} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (2.13)$$

Si $d^2(\mathbf{x}_j, \mathbf{b}_i) = 0$, \mathbf{x}_j est un prototype \mathbf{b}_i et $U_{ij} = 1$ avec $U_{kj} = 0$, $k \neq i$.

Pour C et X fixés, l'annulation des dérivées partielles $H'(\mathbf{B}, \mathbf{g})$ par rapport à une direction quelconque \mathbf{g} de \mathbf{B} donne enfin :

$$\mathbf{b}_i = \frac{\sum_{k=1}^n u_{ik}^m \mathbf{x}_k}{\sum_{k=1}^n u_{ik}^m} \quad (2.14)$$

L'algorithme des C-moyennes floues (FCM) consiste alors en l'application itérée de (2.13) et (2.14) jusqu'à stabilité des solutions. Le critère d'arrêt des itérations, définissant cette stabilité, peut par exemple consister en l'étude de la norme de la matrice \mathbf{U} ou en la stabilité des centres de classe sur deux itérations successives.

b) FCM et caractérisation des tissus cérébraux

L'algorithme FCM a été beaucoup utilisé pour la segmentation des images de cerveau, quels que soient la modalité et le type d'acquisition (mono ou multimodal). De nombreux travaux ont notamment été effectués en imagerie par résonance magnétique. Baumgartner *et al.* [BAU 98] ont ainsi utilisé le FCM pour segmenter les régions activées (simulation et aires motrices) du cerveau. Les pixels étant représentés par leur niveau de gris, les auteurs ont montré non seulement que l'algorithme avait des performances comparables à l'analyse de corrélation standard (avec l'avantage de ne nécessiter aucune connaissance *a priori* sur le paradigme), mais aussi que le FCM détectait des zones effectivement activées qui restaient silencieuses avec la corrélation. En IRM traditionnelle, Clark *et al.* [CLA 94] ont utilisé le FCM comme étape d'initialisation à un système expert pour segmenter des volumes de tumeur ou d'œdème sur des images pondérées en T_1 , T_2 et en densité de protons.

3.3.2.3. Algorithme de classification possibiliste

a) Présentation de l'algorithme PCM

- Recherche de nouvelles contraintes

Krishnapuram et Keller [KRI 96] ont suivi les idées de Zadeh [ZAD 78] selon lesquelles (2.11) ne doit pas contraindre les appartenances d'un vecteur quelconque \mathbf{x}_j si les classes représentées par les nuages sont considérées comme ces sous-ensembles flous sur le domaine $\mathbf{X}=(\mathbf{x}_j, \mathbf{j}=1..N)$. Les degrés d'appartenance doivent seulement appartenir à l'intervalle [0,1]. Ainsi, un nouvel ensemble de contraintes est défini :

$$(\forall i \in \{1..C\})(\forall j \in \{1..N\}) u_{ij} \in [0,1] \text{ et } 0 < \sum_{j=1}^N u_{ij} < N$$

$$(\forall j \in \{1..N\}) \max_i u_{ij} > 0. \quad (2.15)$$

La condition (2.15) assure simplement que la partition floue résultante de l'algorithme recouvre le domaine \mathbf{X} . En toute rigueur, la matrice \mathbf{U} résultante n'est plus une C-partition floue, puisque la contrainte (2.11) n'est plus satisfaite.

▪ *Recherche des nouvelles solutions*

Avec ces nouvelles contraintes, la minimisation de (2.12) produit une solution obtenue en assignant les vecteurs \mathbf{x}_j à une classe et une seule. La fonction $J(\mathbf{B}, \mathbf{U}, \mathbf{X})$ doit donc également être modifiée et Krishnapuram et Keller [KRI 96] proposent de minimiser :

$$J(\mathbf{B}, \mathbf{U}, \mathbf{X}) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i) + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m \quad (2.16)$$

où η_i est un réel positif déterminant la distance à laquelle le degré d'appartenance d'un vecteur à la classe i est égal à 0.5. La même méthode de résolution que celle utilisée pour le FCM donne les degrés d'appartenance U_{ij} et les centres de classe :

$$(\forall i \in [1..C])(\forall j \in [1..N]) \quad u_{ij} = \frac{1}{1 + \left(\frac{d^2(\mathbf{x}_j, \mathbf{b}_i)}{\eta_i} \right)^{\frac{1}{m-1}}} \quad (2.17)$$

et si d induit une norme :

$$(\forall i \in [1..C]) \quad b_i = \frac{\sum_{k=1}^n u_{ik}^m \mathbf{x}_k}{\sum_{k=1}^n u_{ik}^m} \quad (2.18)$$

Notons que le choix de (2.16) n'est pas unique, puisque les mêmes auteurs proposent dans [KRI 96] une autre fonctionnelle :

$$J(\mathbf{B}, \mathbf{U}, \mathbf{X}) = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i) + \sum_{i=1}^C \eta_i \sum_{j=1}^N u_{ij} (\log(u_{ij}) - 1) \quad (2.19)$$

permettant de classer des nuages de points très proches (décroissance exponentielle des degrés d'appartenance U_{ij} en fonction de la distance des vecteurs \mathbf{x}_j aux centres \mathbf{b}_i).

L'algorithme résultant de l'application itérée de (2.17) et (2.18) constitue l'algorithme de classification possibiliste, noté dans la suite PCM.

b) PCM et caractérisation des tissus cérébraux

L'utilisation de l'algorithme de classification possibiliste en imagerie médicale d'une manière générale, et pour la caractérisation de tissus cérébraux en particulier, est peu fréquente. Masulli et Schenone [MAS 99] ont proposé de combiner une approche par réseaux

de neurones avec l'algorithme PCM pour segmenter les tissus cérébraux et des entités pathologiques (ménigiomes). Barra et Boire [BAR 00] ont également appliqué PCM en IRM sur des vecteurs forme x_j .

3.3.2.4. Variations autour des C-moyennes floues

De nombreuses variations de l'algorithme FCM sont possibles, en changeant la fonctionnelle à minimiser, la métrique d ou les contraintes à appliquer. Nous présentons ici quelques variantes plus particulièrement utilisées pour la caractérisation des tissus cérébraux.

- *Méthode FCM semi-supervisée*

Les algorithmes de minimisation utilisés en classification tendent selon certains auteurs [SUC 99] à privilégier les solutions dont les nuages de points ont des populations de taille sensiblement égales. Par conséquent, les amas de faible cardinalité sont intégrés aux nuages plus importants, d'où une classification qui risque d'être anatomiquement incorrecte. Le nombre de classes étant fixé *a priori*, l'absorption d'une classe de faible cardinalité par une classe plus importante résulte nécessairement dans la création d'une classe non significative ou de la partition d'une structure en deux sous-classes. Bensaïd *et al.* dans [BEN 94] Ont alors proposé une version semi-supervisée de l'algorithme des C-moyennes floues. Un ensemble de vecteurs d'apprentissage A est défini par un expert dont chaque élément appartient de façon exclusive à l'une des classes. De plus, une pondération est attribuée à ces vecteurs, qui permet de créer des copies des vecteurs d'apprentissage et ainsi de guider la segmentation vers un résultat anatomiquement correct. Le calcul des degrés d'appartenance des vecteurs n'appartenant pas à A reste inchangé par rapport à un FCM conventionnel. En revanche, la mise à jour des centres de classe nécessite d'intégrer les vecteurs d'apprentissage au calcul :

$$b_i = \frac{\sum_{x \in A} p_i u'_{ik} x + \sum_{x \notin A} u_{ik}^m x}{\sum_{x \in A} p_i u'_{ik} + \sum_{x \notin A} u_{ik}^m} \quad (2.20)$$

où p_i est un facteur de pondération attribué aux vecteurs d'apprentissage de la classe i et U_{jk} est égal à 1 si l'élément k appartient à la classe d'apprentissage i et 0 sinon. Cet algorithme présente deux inconvénients majeurs : il nécessite une intervention humaine pour définir l'ensemble d'apprentissage et introduit les p_i comme paramètres supplémentaires. Dans certaines applications, l'intervention de l'utilisateur peut être évitée. Suckling *et al.* dans [SUC 99] initialisent ainsi les vecteurs d'apprentissage pour la matière grise et la matière blanche d'après l'histogramme de l'image. Ce type d'initialisation non supervisée est possible dans des

cas simples où, malgré un chevauchement des paramètres caractéristiques, les structures sont identifiables sur l'histogramme. Si le facteur de pondération est trop fort, le centre du nuage restera égal au barycentre des vecteurs d'apprentissage de la classe tout au long des itérations. S'il est trop faible, le comportement de l'algorithme semi-supervisé sera similaire à celui d'un FCM conventionnel. L'algorithme semi-supervisé obtient selon ses auteurs de meilleurs résultats qu'un algorithme de ($kppv$) utilisé avec le même ensemble d'apprentissage. Il est donc moins sensible au choix d'un ensemble d'apprentissage médiocre et produit dans ce cas de meilleures segmentations.

Conclusion

Dans ce chapitre nous avons présenté l'ensemble des méthodes de segmentation des images IRM cérébrales. La présentation qui est faite ici n'est pas complète mais nous avons mis en évidence la diversité des approches abordées (**Tableau 1**) par les différents auteurs.

Cette diversité reflète la complexité du problème de segmentation des images IRM cérébrales, ces difficultés sont liées, d'une part, aux objets traités et, d'autre part, à la particularité des images IRM. Le cerveau humain est une entité complexe (*cf.I.1.1*) composée de différentes structures mélangées, à caractères variables importants. Concernant les images IRM, elles fournissent une représentation de l'anatomie cérébrale de qualité mais elles sont sujettes à des incertitudes et des imprécisions vues précédemment, liées, en particulier, aux bruits d'acquisition, au phénomène de dérive du champ radiofréquence, aux effets de volume partiel. . .etc.

D'après l'étude des différentes méthodes citées dans ce chapitre, nous avons relevé (**Tableau 1**) des inconvénients et des avantages pour chacune d'entre elles. Ce qui permis de dire donc qu'il n'existe pas de méthode de segmentation complète (résultats optimaux). Malgré la simplicité de la mise en œuvre des méthodes contours et régions, elles ne sont utilisables que dans des contextes limités (structures particulières), elles nécessitent aussi l'intégration d'informations *a priori* sur les zones recherchées. Ainsi la phase d'apprentissage dans le cas des méthodes supervisées influe considérablement sur les résultats de segmentation [*BAR 99*].

Avec tous ces avantages et ces limites, nous avons pensé à utiliser la coopération de méthodes pour tirer partie des avantages de chacune, l'intérêt de telles approches est qu'elles exploitent la complémentarité d'informations en proposant un système de segmentation complet.

	Approches	Structures a segmentées	Contraintes	inconvénients	Avantages	
Contours	Méthodes dérivatives [MAT 80]	<i>Système ventriculaire</i>	<i>Contrastes entre les structures</i>	<i>-contours non fermés. - très sensibles au bruit La sous- et sur-segmentation</i>	<i>Rapides et ne nécessitant pas d'information a priori</i>	
	Modèle déformable [KAS 88]	<i>Hippocampe Surface corticale</i>	<i>Sensibles à leur initialisation</i>	<i>Non adaptée aux différentes structures</i>	<i>Contours ou surfaces fermés.</i>	
Régions	Seuillage [BRU 93]	<i>MG, MB, LCR</i>	<i>Contraste entre Structures</i>	<i>Nécessitent souvent des post-traitements</i>	<i>Simple à mettre en œuvre, rapide</i>	
	Croissance de régions [THI 97]	<i>MG, Mb, LCR</i>	<i>Disposition des germes initiaux.</i>	<i>Coûteuses en temps de calcul.</i>	<i>Simple à mettre en œuvre</i>	
Statistiques (Classification)	Supervisées	Champs de Markov [HEL 97]	<i>MG, MB, LCR, MB/MG LCS/MG</i>	<i>Base d'apprentissage</i>	<i>Sensibilité</i>	<i>Prennent En compte les relations spatiales</i>
		Kppv [DUD 73]	<i>MG, Mb, LCR</i>	<i>Le paramètre K</i>	<i>Temps de calcul élevé</i>	<i>Simplicité</i>
		Réseaux de neurones [MAG 73]	<i>Putamen, noyau caudé, Corps calleux</i>	<i>Base d'apprentissage</i>	<i>Intervention de opérateur</i>	<i>Apprentissage pour chaque image</i>
	Automatiques	HCM [BEZ 81]	<i>MG, MB, LCR</i>	<i>Centres des classes</i>	<i>Ne prend pas l'incertain et l'imprécis</i>	<i>Automatique</i>
		FCM [BEZ 81]	<i>MG, MB, LCR</i>	<i>Centres des classes</i>	<i>Degrés d'appartenance relatifs</i>	<i>Prend l'incertain et l'imprécis</i>
		PCM [KRI 96]	<i>MG, MB, LCR</i>	<i>Centres des classes</i>	<i>Choix des paramètres</i>	<i>Degrés d'appartenance absolus</i>

Tableau 1 : Comparaison entre méthodes de segmentation

CHAPITRE III : Méthodes de segmentation Coopérative

Introduction

La segmentation des images IRM cérébrales est une problématique complexe, largement traitée dans la littérature [BEZ 93]. Elle nécessite l'introduction et l'extraction de connaissances radiométriques à partir de la distribution d'intensité des tissus ainsi que les défauts des images qui caractérisent le processus d'imagerie par résonance magnétique.

Pour augmenter la robustesse du processus de segmentation, il faut mettre en œuvre la coopération de plusieurs méthodes, tout en combinant différentes sources d'informations ou modalités de traitement pour exploiter les complémentarités entre ces méthodes.

Dans ce chapitre nous allons présenter quelques définitions et les objectifs attendus de la coopération, nous dressons à la fin un état de l'art sur les méthodes de segmentation coopérative.

1. Définitions

- Selon [GAR 00] « la coopération est l'ensemble des techniques visant à combiner plusieurs sources d'information ou modalités de traitement pour accomplir une tâche ».
- « La coopération des classifieurs est un ensemble de méthodes associées mettant en œuvre la combinaison des classifieurs. Elle peut être définie formellement par un ensemble de classifieurs et un ensemble de relations entre ces classifieurs ». [GUN 01]

2. Objectifs et intérêts de la coopération

- Lorsque les classes sont multimodales ou lorsqu'elles se chevauchent, il devient difficile de les modéliser, parce que leur représentation (par exemple, les centres de distributions des probabilités ou des ensembles flous) devient compliquée, surtout dans le cas où la taille de l'ensemble d'apprentissage est limitée. Cette modélisation conduit à une sur-adaptation aux données disponibles qui ne représentent pas forcément les classes réelles. On associant différentes méthodes de segmentation, on espère obtenir de meilleures performances [GER 99].
- Des informations hétérogènes sont manipulées pour segmenter une image, ces informations sont à caractère descriptif ou opératoire, elles décrivent les méthodes permettant au système d'extraire, de manipuler et de combiner d'autres informations (par exemple des informations liées à la segmentation supervisée et automatique).
- Le cas le plus simple dans un processus de segmentation (modèle et image non complexes et non compliqués), peut être traité à partir d'un vecteur de caractéristiques,

que les techniques de classification peuvent regrouper en classe. Le cas le plus difficile est celui d'un modèle et d'une image complexes et compliqués. Il entraîne la nécessité d'une combinaison de stratégies [GER 99].

- L'introduction de nouvelles sources d'information pour segmenter les pixels (grâce à l'emploi de nouveaux modèles ou opérateurs, introduisant par exemple des connaissances anatomiques) est ainsi un moyen non seulement d'améliorer la segmentation de l'image mais aussi d'affiner l'estimation des paramètres de l'ensemble des modèles.
- Exploiter la complémentarité qui existe entre les différentes approches, pour fournir un résultat plus complet et plus précis que ce que les approches prises indépendamment peuvent produire.

3. Types de coopération [GER 99]

La recherche des méthodes de combinaison d'informations dans le but de segmenter des IRM cérébrales a abouti à la définition et à la mise en oeuvre de trois grands principes de coopération :

3.1. Coopération par initialisation (séquentielle)

Cette coopération exploite le résultat d'une méthode pour initialiser une seconde phase de traitement réalisée par une autre méthode (**Figure 17**) : l'image originale est segmentée par la méthode1, cette méthode va générer une image qui va être exploitée par une autre méthode est ainsi de suite.

3.2. Coopération par fusion d'informations (parallèle)

Elle permet de tirer parti de la fusion d'informations complémentaires dans le but de guider un processus de segmentation : l'image originale est segmentée par la méthode1, méthode2, méthode3 ...etc, chaque méthode va générer des données (images) qui vont être fusionnées pour reconstruire l'image finale segmentée.

3.3. Coopération par rétroaction

La coopération par rétroaction permet de revenir sur le processus complet de segmentation pour l'affiner ou encore pour transmettre des informations entre différentes images.

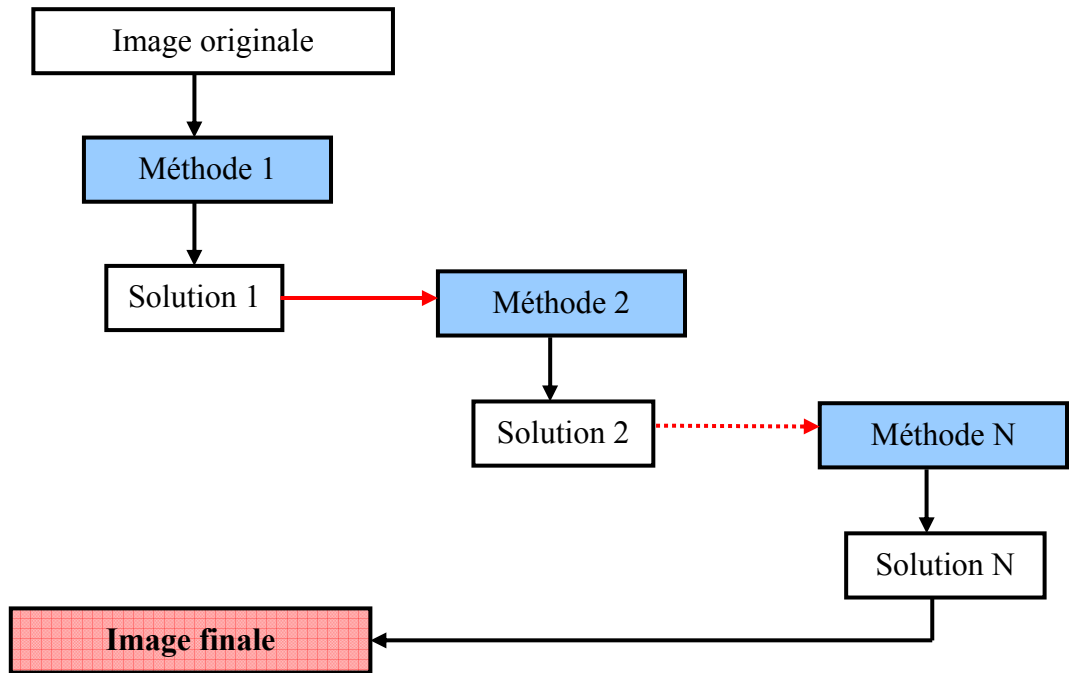


Figure 17 : La coopération par initialisation (séquentielle).

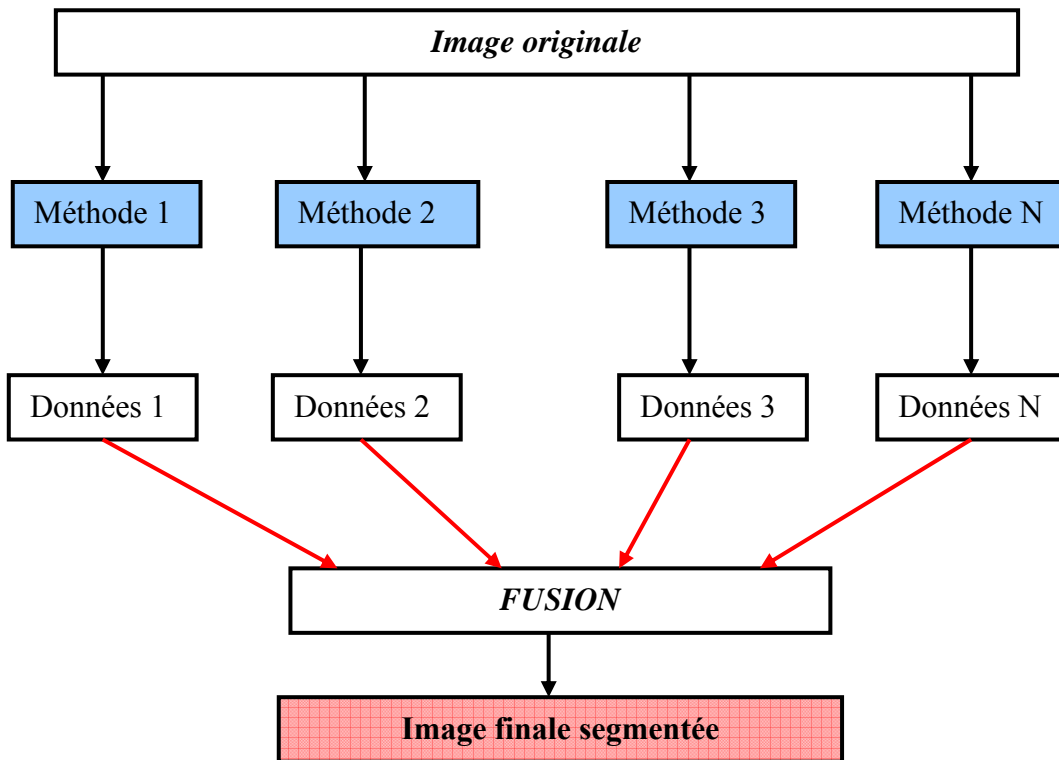


Figure 18 : Coopération par fusion (parallèle)

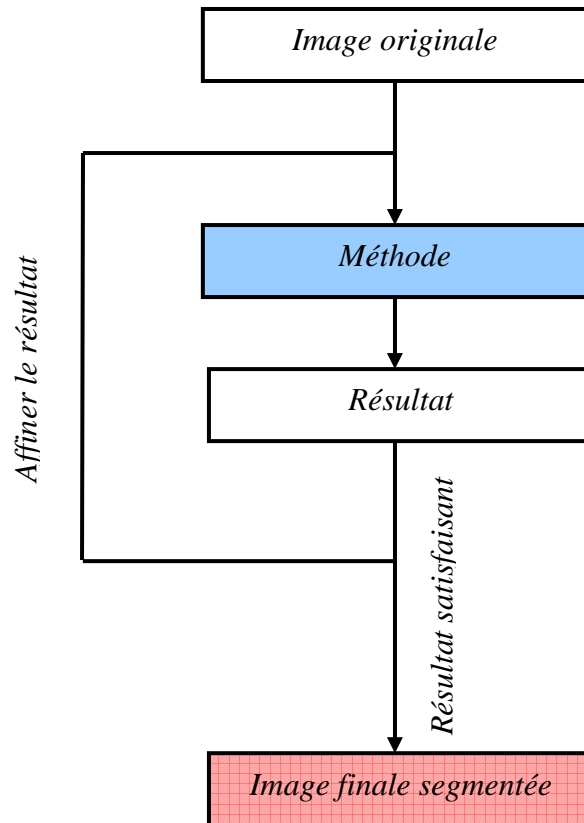


Figure 19: Coopération par rétroaction.

4. Etat de l'art

Au cours de l'étude des approches par classification (cf.II.3), nous avons noté que certaines phases de traitement étaient délicates. L'intérêt de faire coopérer plusieurs approches est donc de réussir à définir automatiquement des ensembles de contraintes pour guider les processus de segmentation. De plus, des principes de fusion d'information peuvent être exploités pour renforcer des critères de décision et influencer les choix de segmentation.

Nous présentons dans cette partie deux grands ensembles d'approches coopératives. Les approches coopératives qualifiées de séquentielles, fondées sur des traitements successifs des données dans le but d'aboutir progressivement à la solution recherchée et les approches qualifiées confrontatives, fondées sur une définition mutuelle de contraintes et qui permettent une fusion de la solution. En fin nous présentons les méthodes dites « hybrides » qui combinent plusieurs approches (séquentielles\ confrontatives).

4.1. Coopération séquentielle

Les approches que nous présentons dans cette section sont principalement fondées sur des principes de corrections de résultats intermédiaires. L'objectif est de réduire progressivement

la difficulté du problème en le décomposant en sous problèmes de plus en plus fins. Plusieurs travaux ont été réalisés avec ce type de coopération [GUN 01].

4.1.1. Coopération séquentielle (Bayésienne\Morphologie mathématique\Contour actif)

Dans [KAP 96], Kapur *et al.* présentent une méthode de segmentation composée de trois principales phases (Figure 20):

1. La première étape consiste à classifier les pixels du volume entier en 4 classes (matière blanche, matière grise, liquide céphalo-rachidien, peau) grâce à une approche de type d'Estimation/Maximisation (E/M proposée dans [WEL 96]. Cette segmentation est effectuée directement sur l'image originale et non sur le résultat d'une procédure d'isolement du cerveau. Il en résulte de fausses classifications que les étapes suivantes visent à corriger.
2. La seconde étape consiste en une érosion, suivie d'une dilatation de l'image classifiée. L'objectif est d'isoler le cerveau du reste de l'image par élimination des connecteurs de petite taille (vaisseaux, muscles, ...etc). Cette étape permet d'ajouter de l'information topologique au résultat de la première étape.
3. Dans le cas où la seconde étape ne permet pas un isolement parfait du cerveau, une troisième étape est effectuée. Elle utilise un modèle déformable de type contour actif, initialisé manuellement, pour détecter le contour du cerveau. L'originalité de cette étape tient dans la définition de l'énergie externe. En effet, cette énergie est liée au résultat de la classification, et pas seulement à l'image brute.

Cette méthode de classification admet des limites concernant les classes segmentées, car elle repose sur une approche supervisée dont le résultat dépend de la base d'apprentissage.

4.1.2. Coopération séquentielle (Morphologie mathématique\bayésienne\Croissance)

Dans les travaux de Warfield *et al.* [WAR 95] les auteurs proposent une coopération séquentielle pour détecter les lésions de la matière grise. Leur approche est très similaire à celle proposée dans [JOH 96]. Ce problème est délicat car les lésions, localisées dans la matière blanche, présentent des niveaux de gris similaires à ceux de la matière grise. Un principe de classification n'est donc pas suffisant pour le repérage des lésions.

1. La première étape consiste à extraire le cerveau du reste du volume 3D grâce à une séparation entre tissus cérébraux et tissus non cérébraux par classification. Cette étape est affinée par un processus d'érosion/dilatation pour éliminer les connexions entre cerveau et crâne.

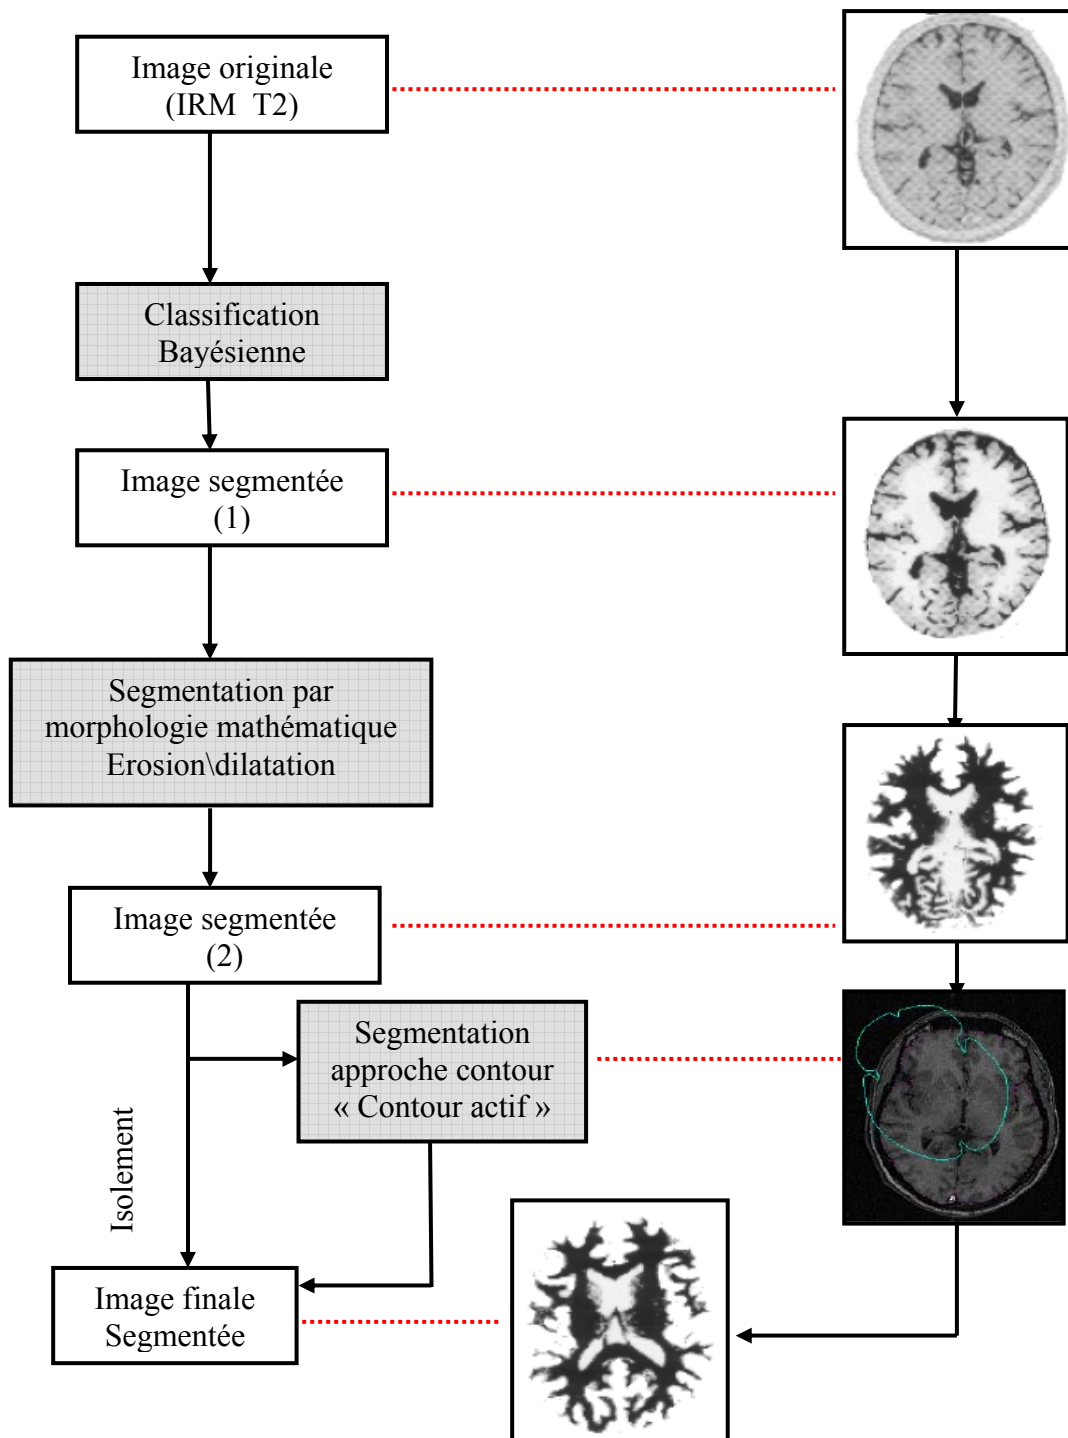


Figure 20 : Exemple de coopération séquentielle (Bayésienne\Morphologie mathématique\Contour actif).

2. La seconde étape fait appel à la classification adaptative par E/M (Bayésienne) proposée dans [WEL 96].
3. La troisième étape a pour objectif de définir un masque pour le cortex. Ceci est réalisé en commençant par éliminer le liquide céphalo-rachidien de la zone d'intérêt grâce à

la classification. Ensuite, l'image représentant l'union de la matière grise et blanche est mise en correspondance avec un atlas par transformations linéaires, complétées par des déformations élastiques. La zone reconnue par cette mise en correspondance ne décrit pas avec exactitude le cortex recherché. Cependant, une dilatation de cette zone permet d'obtenir un masque du cortex.

4. La quatrième étape consiste à utiliser les 2 informations issues de la classification E/M et de la mise en correspondance avec un atlas pour guider une croissance de région dans le cortex.

Les germes utilisés pour la croissance de région sont automatiquement sélectionnés à la surface du cortex et le principe d'agrégation retenu est le suivant : une queue de pixels est initialisée avec les germes et l'algorithme itère tant que la queue n'est pas vide sur la séquence suivante :

- Sélectionner le site V en tête de la queue
 - Pour chaque L dans le voisinage de V : Si L n'est pas déjà dans le cortex et si L est dans le masque du cortex et il est classifié comme matière grise alors marquer L comme cortex, et ajouter L à la queue.
5. La segmentation du cortex permet ensuite de déduire une segmentation de la matière blanche par complémentarité. La détection des lésions est finalement réalisée par séparation de la matière blanche ainsi isolée en 2 classes : matière blanche effective et lésions.

Avec cette approche coopérative, on remarque que le résultat de la segmentation dépend de l'initialisation des germes originaux, ce qui donne une segmentation différente des classes réelles.

Teo et Wandell [TEO 97] proposent une segmentation en deux étapes principales qui permettent de contraindre la topologie de la matière grise (**Figure 21**).

1. Dans une première étape, la matière blanche est segmentée et les contraintes de connexité de tous les pixels la composant sont vérifiées.
2. Dans une seconde étape, la matière grise est obtenue en faisant croître un manteau d'épaisseur constante autour de la matière blanche et en conservant les contraintes topologiques. Cette méthode permet d'exploiter le résultat de la segmentation ultérieurement dans le cadre du dépliement du cortex.

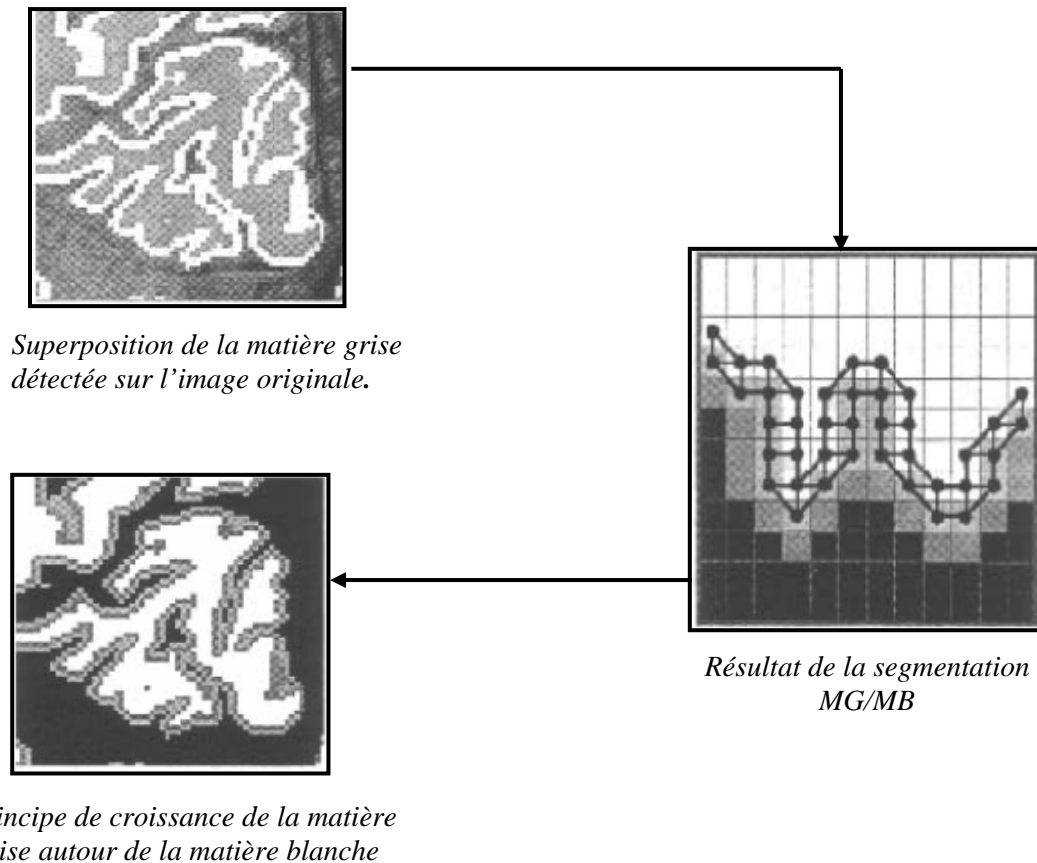


Figure 21 : Segmentation coopérative séquentielle de la MB et MG.

4.1.3. Approche coopérative (Mean-shift \ FCM)

Moussaoui *et al.* [Mou 05] utilisent la classification à base de c-moyennes floues modifiées par l'insertion d'un *bootstrap* modélisé par l'algorithme de *mean-shift* pour la segmentation des tissus cérébraux.

4.1.3.1. Principe de Mean-shift

Cette technique est due aux travaux de Yizong Cheng [CHE 95]. Le *mean-shift* (ou déplacement moyen) est une procédure itérative simple qui fait déplacer chaque point vers la moyenne de ses points voisins. La classification ici est traitée comme un problème de détermination des points fixe qui caractérise les données.

Soit S un ensemble fini de données encadrées dans un espace euclidien de dimension N , X est la moyenne simple pour $x \in X$ est :

$$m(x) = \frac{\sum_{s \in S} K(s-x)}{\sum_{s \in S} K(s-x)} \quad (3.1)$$

La différence $m(x) - x$ est appelée le déplacement de la moyenne. Le mouvement répété des données à la moyenne simple est appelé l'algorithme du déplacement moyen

(*Mean shift Algorithm*). Pour chaque itération de l'algorithme, $s \leftarrow m(s)$ est appliqué pour tous $s \in S$ simultanément. La fonction $K: X \rightarrow \mathbf{R}$ est appelée *Kernel* (noyau).

4.1.3.2. Les étapes de coopération

1. Lancer le *mean-shift* pour retrouver les centres des classes.
2. Une fois les noyaux trouvés, l'initialisation du FCM par ces derniers.
3. Relancer la classification par FCM.

L'originalité de l'approche réside dans l'insertion d'un algorithme *bootstrap* qui corrige les classes obtenues *a priori*. La technique fait appel à l'algorithme de *mean-shift* qui, par sa capacité d'expansion et de détection de modes, est entretenu suivant un processus d'itération vérifiant le critère basé sur la minimisation des erreurs quadratiques des intraclasse.

Selon les auteurs l'association conjuguée du *mean-shift* et du FCM est bien adaptée pour analyser les images médicales. La procédure d'analyse et de classification est évolutive et non supervisée, ce qui permet d'obtenir un rendu de traitement proche de la réalité puisque les structures anatomiques saines ou pathologiques sont de formes quelconques.

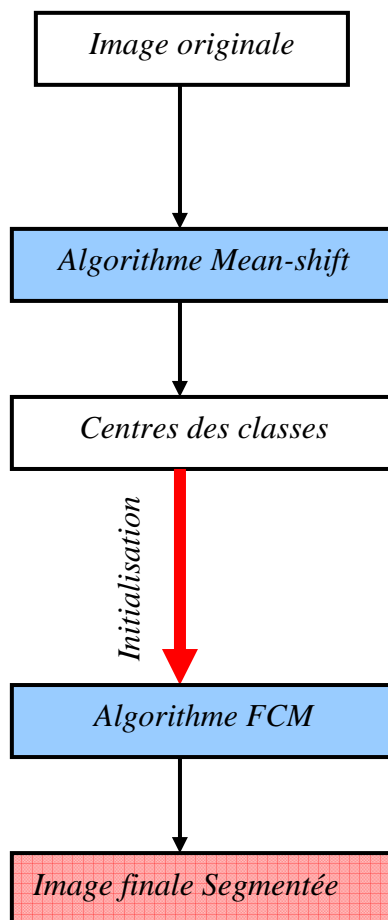


Figure 22: La coopération Mean-shift , approche flou.

L'utilisation d'un certain nombre de méthodes, selon un schéma séquentiel, pour réaliser la segmentation reflète bien la nécessité de faire intervenir des informations variées pour résoudre le problème.

Les approches par classification permettent de détecter des régions, les modèles de contours permettent d'isoler des organes. Cependant, utilisés indépendamment, ils manquent parfois d'informations à caractère *complémentaire* pour résoudre toutes les difficultés, comme l'écrit Kapur dans [KAP 96]:

“Nous présentons notre méthode pour la segmentation des tissus cérébraux qui combine les avantages des méthodes existantes avec quelques nouvelles idées et qui sont plus robustes que ses méthodes prises individuellement”.

L'intérêt de la coopération séquentielle réside dans le fait de pouvoir exploiter des complémentarités. Il s'agit essentiellement de définir des méthodes permettant de générer automatiquement des contraintes et des informations exploitables par d'autres modules.

4.2. Coopération par fusion

Plutôt que d'exploiter séquentiellement plusieurs approches pour améliorer la segmentation, il peut être intéressant d'exécuter simultanément plusieurs modules de segmentation. L'objectif est de construire la segmentation progressivement, en optimisant à chaque étape les résultats obtenus par chaque méthode mise en jeu. Il existe relativement plusieurs approches proposant un tel type de coopération pour la segmentation des images IRM cérébrales.

4.2.1. Approche basée sur la théorie des jeux [Boz 94]

4.2.1.1. Principe

Le principe de base de la théorie des jeux de *Nash* est de pouvoir associer à chaque joueur une fonction de coût. Le déroulement d'une partie est alors assimilé, pour chaque joueur, à la recherche d'une stratégie optimale, c'est à dire à l'optimisation de sa fonction de coût.

Ce cadre théorique s'applique aux jeux où les joueurs jouent chacun leur tour et pour lesquels la stratégie d'un joueur est influencée par celle de ses adversaires. De tels jeux font partie de l'ensemble des jeux de *Nash*.

4.2.1.2. Fonctions de coût

Afin de clarifier les formulations, on se limitera dans ce qui suit au cas de 2 joueurs. La fonction de coût d'un joueur est composée de 2 termes décrivant d'une part la stratégie du joueur lui-même (f_i) et d'autre part l'influence du jeu de l'adversaire sur son jeu (f_{ij}). A

chacun de ses coups, chaque joueur fournit de l'information à l'autre via un ensemble (p_i) de paramètres. La fonction de coût d'un joueur dépend donc de ses propres paramètres ainsi que des paramètres de l'autre joueur, ceci permet de traduire la stratégie d'un joueur ainsi que l'influence de la stratégie de son adversaire sur sa propre stratégie.

Les 2 fonctions de coût ont la structure suivante :

$$F_1(p_1, p_2) = f_1(p_1) + \alpha f_{21}(p_2, p_1) \quad (3.2)$$

$$F_2(p_1, p_2) = f_2(p_2) + \beta f_{12}(p_1, p_2) \quad (3.3)$$

4.2.1.3. Recherche de la solution optimale

On note k l'indice de temps qui décrit la séquentialité du jeu. A chaque instant, chaque joueur a la connaissance du jeu de l'autre au temps précédent. Il utilise cette information pour déterminer son nouvel ensemble de paramètres.

Le jeu se termine lorsque les joueurs ne peuvent plus faire évoluer leur ensemble de paramètres vers une meilleure solution. Cet état s'appelle l'équilibre de *Nash*, il caractérise la solution optimale du jeu étudié.

4.2.1.4. Intérêt pour la segmentation

Le principal intérêt pour la segmentation est de permettre le découplage des fonctions objectif lorsque l'approche requiert un processus d'optimisation complexe. En remplaçant la notion de joueur par celle de méthode de segmentation, on peut en effet envisager un schéma d'optimisation itératif (**Figure 23**). A chaque itération, un module ne minimise que selon ses propres paramètres et n'a donc pas besoin de connaître les fonctions de coût des autres modules. L'échange des paramètres est effectué entre 2 itérations. La conséquence directe est une simplification des algorithmes d'optimisation. De plus, l'aspect itératif du processus permet un affinement progressif de la solution, ce qui peut être intéressant en segmentation.

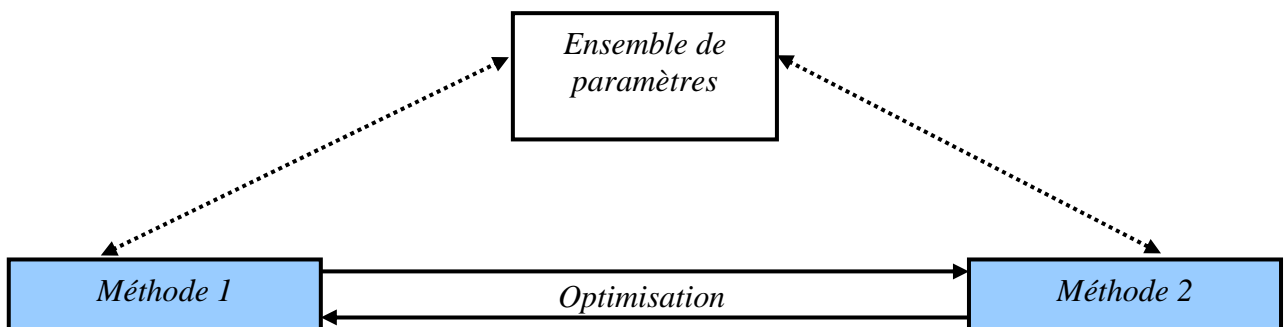


Figure 23 : schéma d'optimisation itératif

4.2.2. Coopération Contour\ Contour

Dans [Boz 94] les auteurs présentent une approche fondée sur la théorie des jeux pour contrôler un processus de coopération entre 2 méthodes de détection de contours. Le rôle de la *méthode1* est de détecter localement des structures pouvant représenter des contours et le rôle de la *méthode2* est de détecter globalement un contour 2D.

La sortie de la *méthode1* est représentée par l'ensemble des structures de contours localement détectées et la sortie de la *méthode2* est constituée des paramètres du contour 2D.

La fonction objectif de la *méthode1* consiste à :

1. Renforcer les structures locales de contours et éliminer le bruit par la mise en correspondance des contours locaux déjà trouvés.
2. Assurer la cohérence avec le résultat de la *méthode2*, principalement par corrélation entre les résultats des deux méthodes.

La fonction objectif de la *méthode2* consiste à :

1. Trouver un modèle déformable du contour.
2. Assurer la cohérence avec le résultat de la *méthode 1*.

L'intérêt de l'aspect itératif de cette approche est de permettre une interaction fine entre les résultats des deux détections. Les influences mutuelles sont en effet calculées à partir d'informations locales et permettent des corrections des contours détectés.

4.2.3. Coopération Champ de Markov\ Contour

Chakraborty et Duncan [CHA 99] proposent, dans le cadre de la théorie des jeux, une approche coopérative entre une méthode de détection de régions et une méthode de détection de contours.

La *méthode1* sert à la détection des régions homogènes de l'image. Le principe utilisé est celui des champs de Markov. Le principe de la fonction objectif de la *méthode1* est de :

1. Segmenter la région X connaissant l'image Y , ce qui est équivalent à maximiser la probabilité suivante : $MAX_x(X / Y)$
2. Traduire l'influence des paramètres P , du contour sur le module région. On cherche à maximiser la probabilité d'avoir une région X connaissant non seulement l'image Y mais aussi les paramètres P . La probabilité $Max(X / Y, P)$ représente l'influence du contour sur la région X .

La *méthode2* sert à la détection des contours. Elle utilise une paramétrisation par coefficients de Fourier et sa fonction objectif traduit :

1. La recherche des paramètres de Fourier, qui constitue en soi une optimisation.
2. L'influence du module région sur le module contour est formulée par une probabilité conditionnelle. Soit G une image de gradient, et X la segmentation région. On cherche à maximiser la probabilité $MAX(P/G, X)$ d'avoir le contour P connaissant non seulement le gradient mais aussi la segmentation région X .

Cette comparaison d'approches traduit l'importance d'une influence progressive entre informations d'une méthode sur une autre. Il semble donc plus généralement que la coopération entre approches doit être relativement fine pour aboutir à des solutions satisfaisantes en termes algorithmiques et de résultats.

4.2.4. Approche coopérative croissance de régions\contours

Y.Cherfa *et al.* [CHE 04]. ont appliqué une coopération basée sur la dualité régions-contours, pour la caractérisation des accidents vasculaires cérébraux, elle s'articule autour des étapes suivantes:

1. Extraction de contours : par la méthode de Dérêche [DER 87], elle présente la propriété d'être paramétrable et robuste.
2. Elimination des petites chaînes de contours : la présence dans le bloc de zones bruitées ou texturées donne lieu à de faux contours, plutôt courts et sans interprétation sémantique. Cette phase utilise un seuillage pour éliminer ces faux contours. Le seuil dépend des informations *a priori* sur l'image à analyser.
3. Croissance de régions qui doit vérifier un double critère, la croissance s'arrête quand le critère d'homogénéité (niveau de gris) n'est plus vérifié ou que le pixel à agréger coïncide avec un pixel contour de la carte contours. La croissance sera donc contrainte par les contours.
4. Fusion des petites régions mal segmentées : du fait de la contrainte des contours et du choix des paramètres dans la phase précédente, de petites régions seront générées. Celles-ci vont être fusionnées avec les régions « Parentes », en faisant un triple test sur leur taille, sur leur niveau de gris par rapport au niveau de gris des régions parentes et sur le fait qu'elles coïncident avec des points contours. Ces petites régions seront fusionnées avec la région adjacente la plus similaire en niveau de gris.
5. Elimination des régions parasites : Après la croissance de régions, de petites régions parasites localisées entre 2 régions adjacentes peuvent surgir. Là aussi, si le nombre de pixels contenus dans ces régions est inférieur à un seuil, elles seront fusionnées avec la région adjacente la plus proche spatialement et en niveau de gris.

6. Elimination des faux contours contenus dans des régions par vérification qu'ils n'en existent pas, et qui sont noyés dans des régions homogènes. Dans le cas contraire, ils doivent être éliminés.
7. Fermeture de contours par suivi de frontières : Les contours produits lors d'une segmentation sont rarement fermés. Cette fermeture, nécessaire, se fait en faisant un suivi de la frontière la plus proche (en termes de distance euclidienne).

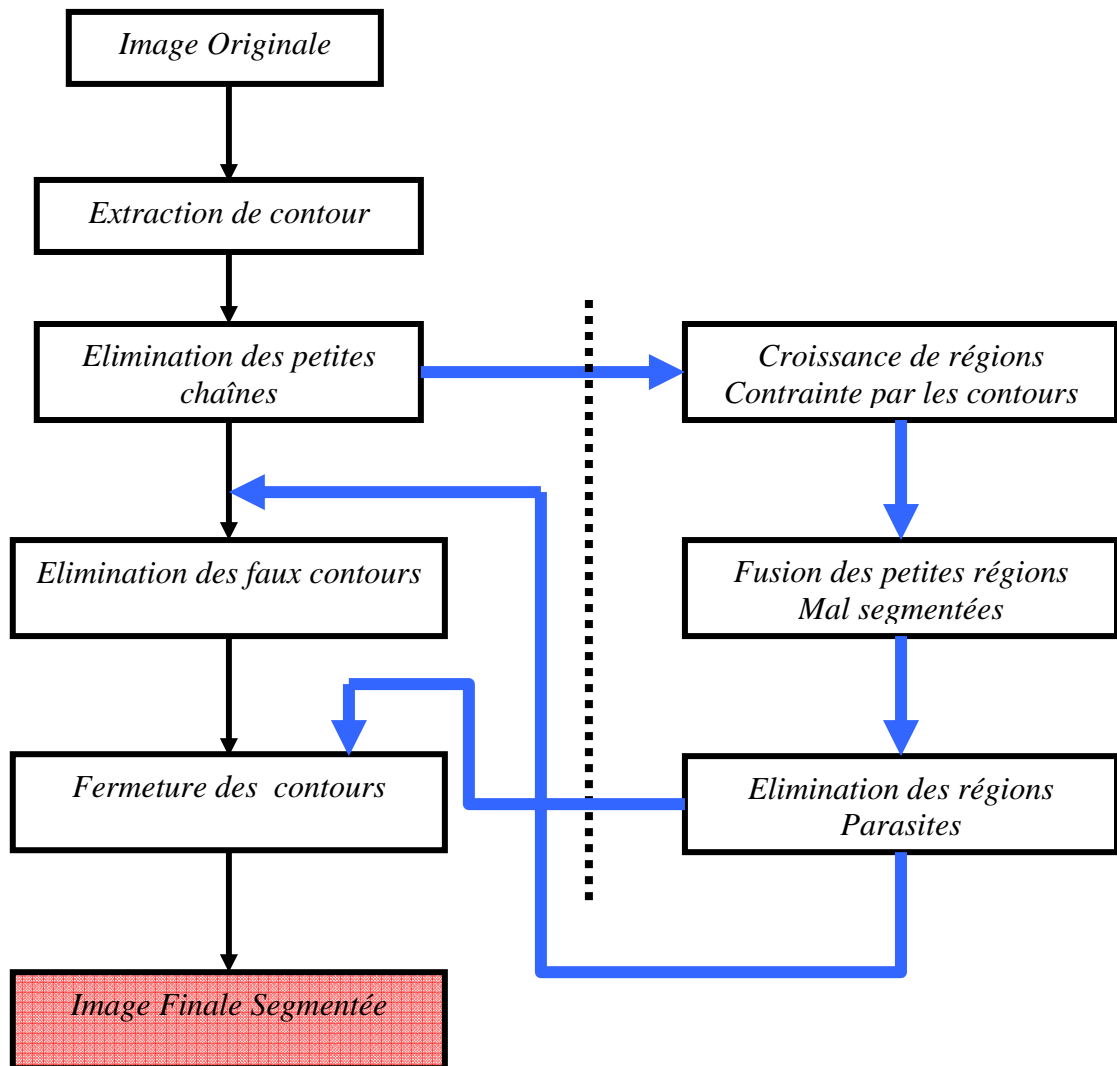


Figure 24 : Les étapes de coopération croissance de régions\contours

4.3. Coopération Hybride

Si le système opère avec plusieurs types d'associations de méthodes (initialisation \fusion\rétroaction), le système est dit hybride [GUN 01].

4.3.1. Approche coopérative hybride Floue/croissance de régions

R. Haroun *et al* [HAR 04]. ont proposé l'utilisation de deux types d'algorithmes : le FCM qui étudie l'image dans sa globalité et permet de modéliser l'incertitude et l'imprécision et, la croissance de régions qui tient compte des relations de voisinage entre pixels, le but étant de tirer partie des avantages de chacun.

4.3.1.1. Principe

Les systèmes de classification génèrent des classes de pixels sans tenir compte de leur position dans l'image, ni de leurs relations topologiques, la classification se fait de la même façon que pour un ensemble de données positionnées d'une manière aléatoire. La croissance de régions tient compte d'une manière simultanée des relations topologiques et des caractéristiques d'homogénéité des régions, et dans la plupart des cas le choix des points germes n'est pas évident.

Les IRM sont souvent caractérisées par des données incertaines, ceci est principalement dû à l'effet de volume partiel, un pixel ayant un certain niveau de gris peut représenter un mélange de deux tissus cérébraux. Pour tenir compte de cet artefact, il faut donner aux pixels non pas le label de leur classe unique, mais leurs degrés d'appartenance à chacune des classes. Les auteurs ont adopté la méthode de classification floue FCM. Cette méthode permet aussi, de considérer l'imprécision causée par le bruit et l'inhomogénéité dans les images.

Pour pallier les limites des systèmes de classification, sans perdre leurs avantages, ils ont utilisé la méthode de croissance de régions, conjointement avec la FCM.

Dans leur travail, ils visent à segmenter l'image en MG, MB et LCR. S'ils utilisent la croissance de régions de manière séquentielle, les germes correspondant au premier tissu qui commencent leurs croissances peuvent envahir d'autres régions et prendre des pixels d'une autre région. Pour pallier ce problème, la croissance s'effectue de manière simultanée pour les trois classes.

4.3.1.2. Etapes de la coopération

L'algorithme proposé déroule en deux étapes:

1. Une première classification basée sur le FCM pour obtenir les degrés d'appartenance de chaque pixel à une classe donnée. Certains pixels ont des degrés d'appartenance à une classe élevés, si $u_{ik} > 0.8$ ces pixels font partie de cette classe.
2. Positionnons des points sur l'image de manière régulière avec un pas de sept pixels, ce choix s'est fait expérimentalement, pour une image de taille 256*256. Ces points sont positionnés uniquement dans la zone de l'encéphale. Ce sont des germes éventuels. Si

leurs degrés d'appartenance sont supérieurs au seuil fixé alors ils sont pris comme des germes, sinon ils sont rejetés.

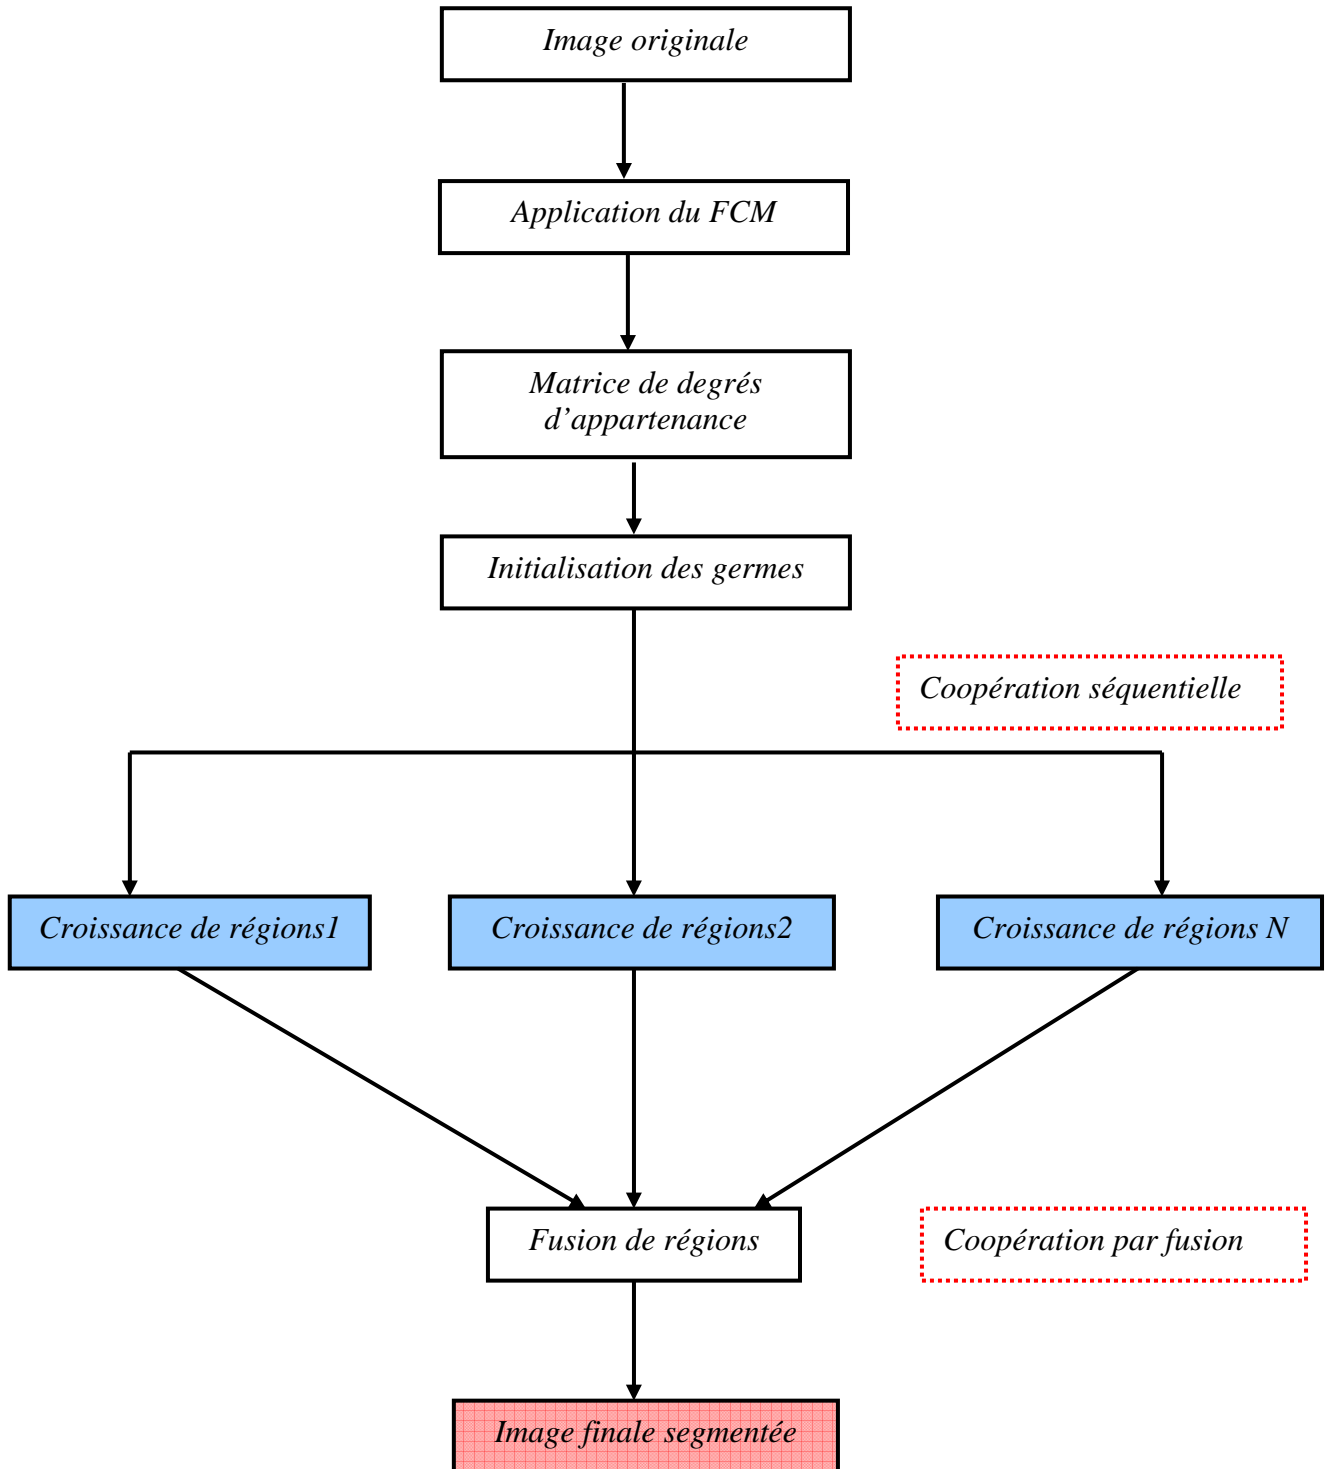


Figure 25 : Coopération hybride Floue\croissance de régions

Le système décrit dans la **Figure 25** est hybride, le processus de segmentation se déroule en deux étapes: la première une coopération par initialisation (séquentielle) par FCM, et la deuxième est la fusion des résultats de chaque croissance de région.

Selon ces auteurs l'utilisation combinée de plusieurs algorithmes de segmentation travaillant en coopération permet de pallier les problèmes causés par l'utilisation d'un seul algorithme, en exploitant seulement les avantages de chacun. L'approche empêche les pixels d'une région d'être ajoutés à la première région du premier germe qui commence la croissance

4.3.2. Approche coopérative hybride (*Modèle déformable\Régions\Contour\Rétroaction* [GER 99])

Une caractéristique importante de l'approche est l'intégration au sein d'un même système un ensemble d'approches variées. Le but est d'exploiter la complémentarité des approches mises en oeuvre pour fournir un résultat plus complet et plus précis que ce que les approches prises indépendamment peuvent produire.

4.3.2.1. Principe de fonctionnement de l'approche

On peut distinguer quatre phases essentielles dans le fonctionnement du système. La première concerne la construction du modèle déformable, la seconde la segmentation en régions par un système multi-agents, la troisième la segmentation de contours et la quatrième le processus de rétroaction.

4.3.2.2. Etapes de la coopération

1. Construction du modèle

Cette phase ne correspond pas directement à une phase de l'exécution du système. Elle constitue en effet une phase d'apprentissage, réalisée une fois pour toutes, avant toute exécution du système.

Cet apprentissage est cependant indispensable. Il consiste à marquer interactivement le contour du cerveau dans un ensemble d'images constituant la base d'exemples. C'est à partir de ce marquage qu'un modèle statistique déformable du contour du cerveau est construit.

Lors de l'exécution du système, la recherche du contour du cerveau par le modèle déformable est la première action réalisée. Elle permet de conditionner le déroulement des phases suivantes du processus de segmentation.

2. Segmentation en régions

La segmentation en régions de la matière grise et de la matière blanche constitue la seconde phase du fonctionnement du système. Cette phase peut être décomposée en deux phases successives :

- a) La segmentation de la matière grise est réalisée par des agents spécialisés localement et initialisés grâce à la connaissance du contour du cerveau détecté par le modèle déformable.
- b) Une segmentation de la matière blanche est ensuite réalisée dans les zones non-segmentées par les agents matière grise. Les agents matière blanche sont également spécialisés localement.

3. Détection des contours

A l'issue de la segmentation en régions, des agents contours spécifiques pour reconstruire un contour du cerveau plus précis que celui fourni par le modèle sont opérés. L'objectif est de s'affranchir des contraintes globales qui sont appliquées au contour modélisé.

Cette étape est réalisée dans un cadre de coopération par *fusion* d'informations, les informations utilisées étant issues des étapes précédentes du processus de segmentation ainsi que d'un module indépendant de détection de contours.

4. Retroaction :

Dans un troisième cadre coopératif, celui de la coopération par rétroaction (*cf.* III.3.3), un retour sur le processus complet de segmentation est envisagé, en considérant le contour reconstruit par les agents contours comme remplaçant du modèle déformable. Le nombre de boucles de rétroaction nécessaires est fixé par les auteurs à 3 après plusieurs expérimentations.

Le retour sur le processus de segmentation peut être effectué sur la même image dans un but d'affinement de la solution ou bien sur une coupe adjacente dans un but de transmission de l'information. La **Figure 26** illustre l'ensemble des étapes de cette approche.

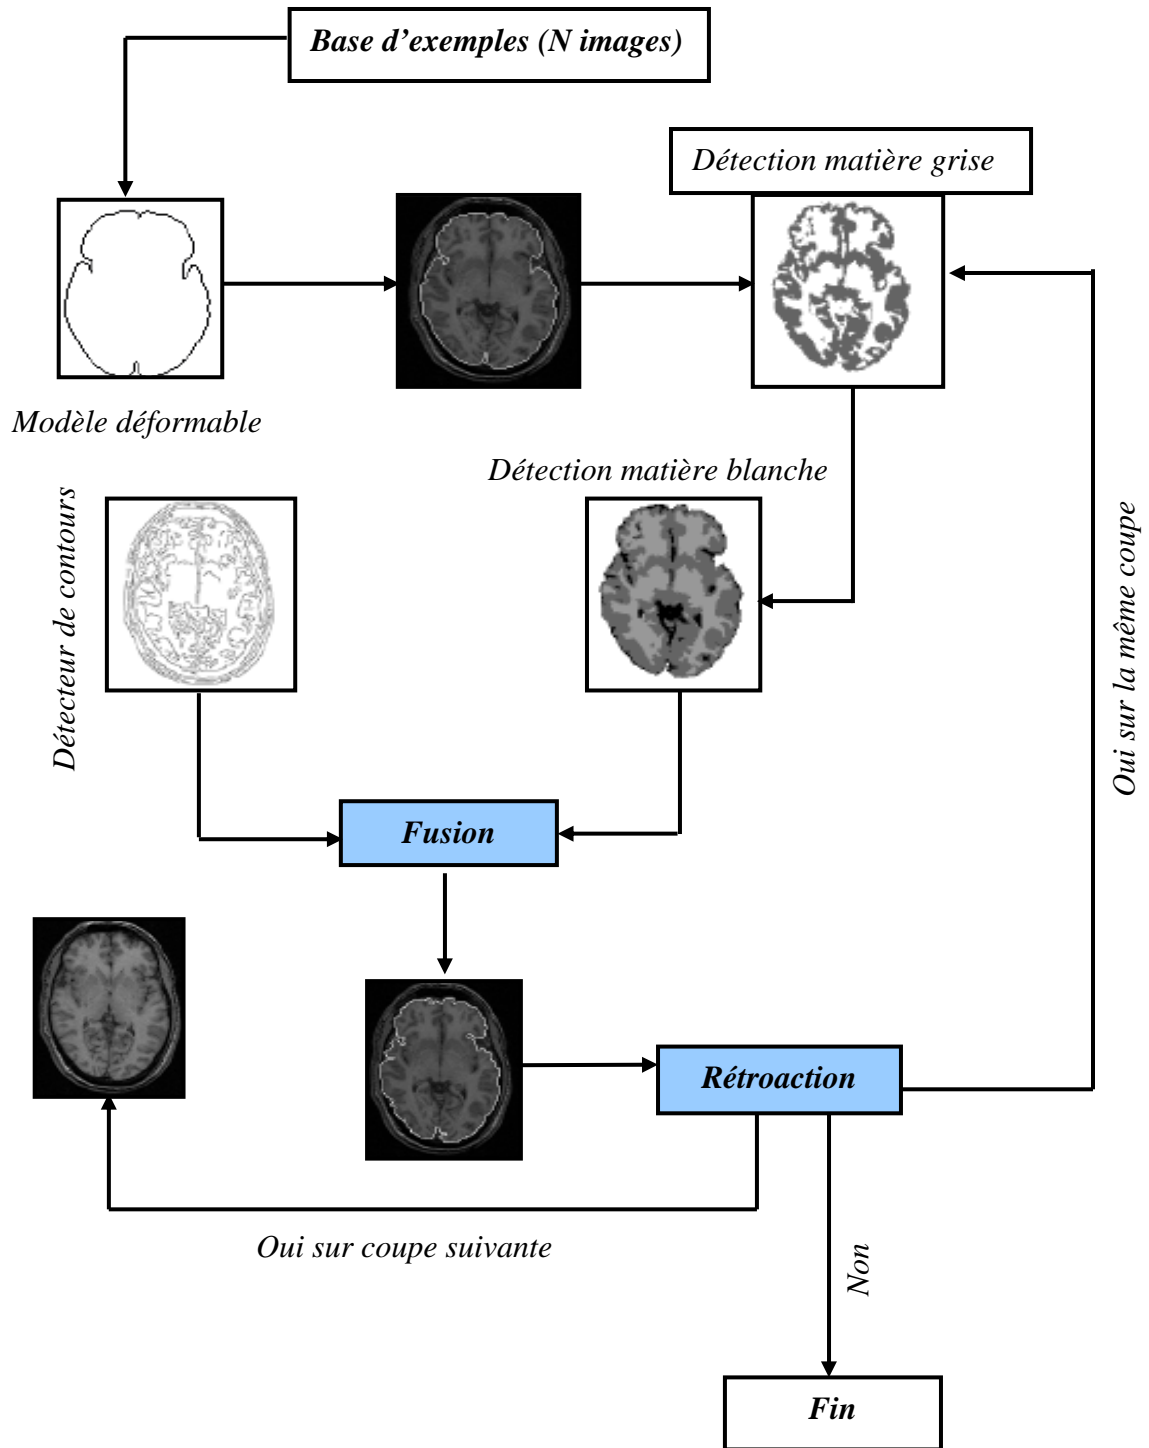


Figure 26 : Approche hybride séquentielle \ fusion \ rétroaction.

Conclusion

Dans ce chapitre, nous avons présenté un état de l'art couvrant un vaste ensemble d'approches coopératives dédiées à la segmentation des images IRM, ces méthodes ayant des objectifs plus globaux pour la réalisation de systèmes de segmentation complets. Nous avons présenté également les méthodes dites hybrides qui utilisent plusieurs types de coopération (séquentielle\fusion\rétroaction).

Tout l'enjeu de cette coopération réside dans la définition de modes de combinaison adaptés à différentes sources d'informations, pour pouvoir exploiter au mieux leurs complémentarités et extraire une information utile et pertinente pour la segmentation.

Les systèmes de classification sont composés d'un grand nombre d'entités traduisant des connaissances hétérogènes. Il est donc nécessaire de fournir un cadre favorisant une intégration harmonieuse de ces composants. La majorité des systèmes de segmentation utilisent une des approches de l'IAD (intelligence artificielle distribuée) comme architecture logicielle de contrôle], ainsi une approche pour la segmentation devrait combiner deux notions apparemment contradictoires qui sont : la définition et la mise en oeuvre de contraintes et une certaine liberté d'exécution, dans le cadre des contraintes définies [GER 99].

L'utilisation d'une approche multi-agents répond particulièrement bien à la double exigence précisée ci-dessus [GER 99]. En effet, les agents doivent être contraints pour effectuer correctement les tâches de segmentation qui leur sont assignées. Cependant, dans le cadre des contraintes fournies, les agents conservent une certaine liberté d'exécution. Les justifications de tel choix sont nombreuses, elles vont être détailler dans le chapitre suivant où on va présenté les systèmes multi agents et leur utilisation dans le contexte de segmentation des IRM cérébrales.

CHAPITRE IV : Systèmes multi-agents, application à la segmentation.

Introduction

La préoccupation majeure de l'intelligence artificielle est de concevoir des systèmes capables de reproduire le comportement de l'être humain dans ses activités mentales, notamment celles de raisonnement. Ces activités sont de nature variée (perception, planification, diagnostique, interprétation des données, compréhension, conception, prise de décision...etc). Ainsi la résolution coopérative des problèmes prend une place prépondérante dans les recherches en intelligence artificielle distribuée (IAD). Un domaine de recherche relativement complexe, dérivé de l'IAD, est celui des systèmes multi-agents (SMA). La thématique SMA se focalise sur l'étude des comportements collectifs et sur la répartition de l'intelligence sur des agents plus ou moins autonomes, capables de s'organiser et d'interagir pour résoudre des problèmes [Woo 01].

A la différence de l'Intelligence Artificielle (IA) qui modélise le comportement intelligent d'un seul agent, l'intelligence artificielle distribuée (IAD) s'intéresse à des comportements intelligents qui résultent de l'activité coopérative de plusieurs agents. Suite à la distribution de l'expertise sur un ensemble de composants qui communiquent pour atteindre un objectif global ou résoudre un problème.

Dans cette partie on va présenter les principes des agents et les systèmes multi-agents, tout en concentrant sur leurs utilisations dans la segmentation des IRM cérébrales.

1. Historique

L'IA a initialement été inspirée de la métaphore du penseur solitaire : les chercheurs dans ce domaine ont cherché à produire des programmes isolés en émulant les processus cognitifs humains pour résoudre des problèmes complexes.

Cette approche va cependant subir trois bouleversements qui vont voir apparaître de nouveaux courants : dans un premier temps, le courant de « *l'intelligence incarnée* » va remettre en cause l'intelligence artificielle comme la manipulation de symboles et de représentations de connaissances pour s'intéresser à la problématique de l'action et de l'interaction avec un monde extérieur. Ce courant s'est intéressé aux systèmes qui agissent plutôt qu'aux systèmes qui raisonnent, la manipulation de représentations ne constituant qu'un aspect de cette nouvelle problématique [MAN 02].

Dans un second temps, l'apparition de l'intelligence artificielle distribuée (IAD) a remis en question l'étude des systèmes constitués d'un agent. Weiss [WEI 99] présente l'intelligence Artificielle distribuée de la manière suivante :

« *L'Intelligence Artificielle Distribuée est l'étude, la construction et l'application des systèmes multi-agents, c'est-à-dire des systèmes dans lesquels des agents intelligents en interaction poursuivent un ensemble de buts ou effectuent une certaine tâche* ».

La métaphore du penseur solitaire a été remise en question et s'est accompagnée d'une nouvelle problématique : celle de l'interaction entre plusieurs entités. Une nouvelle question se pose alors : comment un agent peut-il prendre en considération la présence d'autres acteurs dans le système pour interagir au mieux avec eux ?

Dans un troisième temps, l'utilisation des processus de prise de décision complexes basés sur des représentations symboliques a été remise en cause par le développement d'agents réactifs basés sur des règles simples de type stimulus-réponse [BRO 91]. Cette approche inspirée en partie par l'éthologie, revendique la possibilité de s'affranchir de processus cognitifs élaborés pour résoudre un problème complexe. L'enchaînement de règles comportementales extrêmement simples peut conduire à l'apparition d'un comportement complexe pouvant être qualifié d'intelligent par un observateur extérieur.

L'approche réactive a trouvé ses échos en IAD et pose la problématique de l'apparition de comportements collectifs et des relations entre les comportements individuels simples et locaux des agents, leurs agencements à l'exécution et la tâche collective à résoudre.

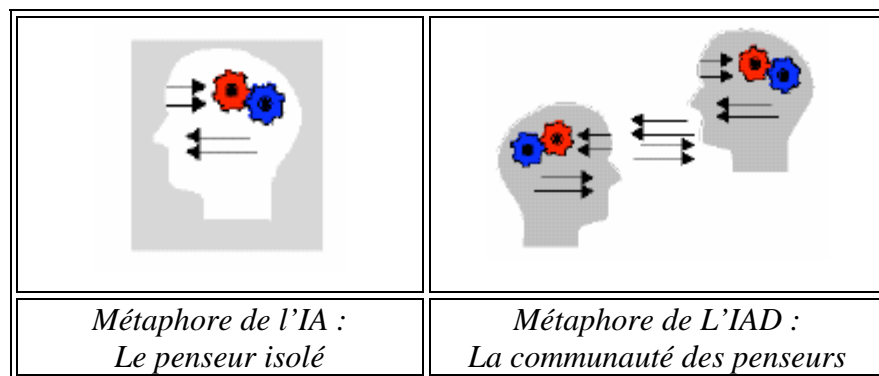


Figure 27 : Différence entre IA et IAD.

2. Les Agents

2.1. Notion d'agent

Il n'y a pas une définition acceptée à l'unanimité pour la notion d'agent.

- « *Un agent est une entité qui fonctionne continuellement et de manière autonome dans un environnement où d'autres processus se déroulent et d'autres agents existent* » [SHO 93].
- « *Un agent est une entité autonome, réelle ou abstraite, qui est capable d'agir sur elle-même et sur son environnement, qui, dans un univers multi-agents, peut communiquer*

avec d'autres agents, et dont le comportement est la conséquence de ses observations, de ses connaissances et des interactions avec les autres agents » [FEB 95].

- « Un agent est une entité qui perçoit son environnement et agit sur celui-ci » [RUS 97].
- « Un agent est un système informatique, situé dans un environnement, et qui agit d'une façon autonome pour atteindre les objectifs (buts) pour lesquels il a été conçu » [Woo 00].
- « Les agents intelligents sont des entités logiciels qui réalisent des opérations à la place d'un utilisateur ou d'un autre programme, avec une sorte d'indépendance ou d'autonomie, et pour faire cela ils utilisent une sorte de connaissance ou de représentation des buts ou des désires de l'utilisateur »².

D'après toutes ces définitions on peut dégager des caractéristiques d'agent.

2.2. Caractéristiques des Agents

On peut identifier les caractéristiques suivantes pour la notion d'agent [Woo 01]:

- a) **Situé** : l'agent est capable d'agir sur son environnement à partir des entrées sensorielles qu'il reçoit de ce même environnement. Exemples : systèmes de contrôle de processus, systèmes embarqués, ...etc.
- b) **Autonome** : l'agent est capable d'agir sans l'intervention d'un tiers (humain ou agent) et contrôle ses propres actions ainsi que son état interne.
- c) **Flexible** : l'agent dans ce cas est :
 - *Capable de répondre à temps* : l'agent doit être capable de percevoir son environnement et élaborer une réponse dans les temps requis.
 - *proactif* : l'agent doit exhiber un comportement proactif et opportuniste, tout en étant capable de prendre l'initiative au bon moment.
 - *Social* : l'agent doit être capable d'interagir avec les autres agents (logiciels et Humains) quand la situation l'exige afin de compléter ses tâches ou aider ces agents à accomplir les leurs.
- d) **Intentionnel** : l'agent n'effectue des tâches que s'il a l'intention de les accomplir. Cette qualité représente l'état mental de l'agent. Selon [MAN 02] ce concept est difficile à définir et les définitions données dans la littérature font intervenir beaucoup de concepts.
- e) **Adaptatif** : l'agent doit être sensible à tous les changements pour qu'il puisse contrôler ses aptitudes (communicationnelles, comportementales) selon l'agent avec qu'il interagit. Cette caractéristique représente un niveau supérieur de flexibilité.

² Agent IBM

2.3. Architecture des agents [MAN 02]

Un agent est caractérisé par son architecture et son comportement. L'architecture consiste à décrire la façon d'assembler les différents composants de l'agent de façon qu'il puisse accomplir les actions attendues, tandis que le comportement décrit la relation qui existe entre l'agent et son environnement.

Un agent peut être caractérisé par des connaissances sur :

- Ses compétences
- Ses capacités d'observation.
- Ses moyens de communication avec les autres agents
- Ses motivations

La **Figure 28** illustre la structure d'un agent

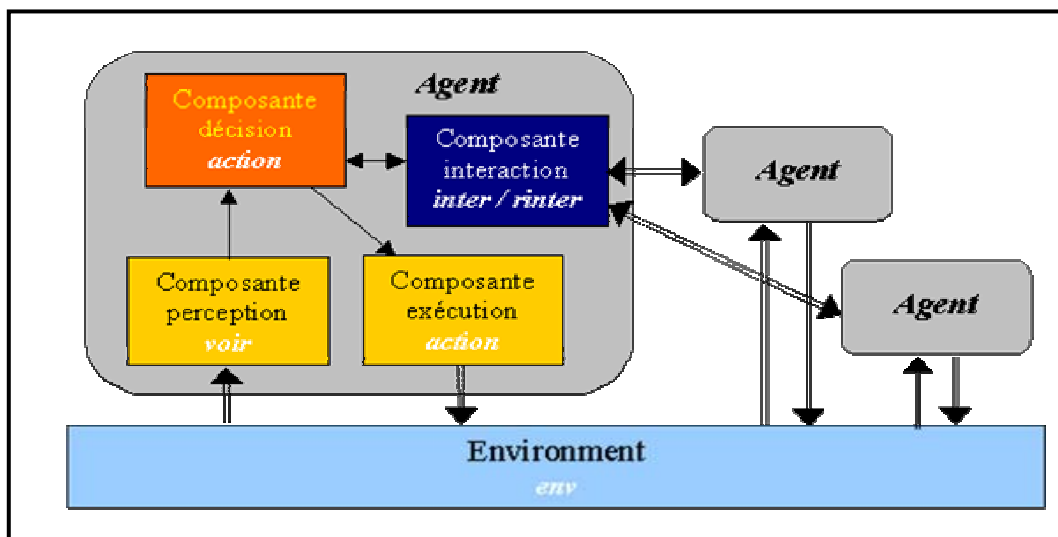


Figure 28 : Structure générale d'un agent qui interagit avec d'autres agents.

Il faut noter que la structure présentée dans la **Figure 28** caractérise les agents intelligents en général, et que la composante interaction avec d'autres agents n'est pas souvent présente dans le cas des agents réactifs.

2.4. Capacités d'un agent

En réalité, même si un agent veut accomplir une certaine action, il doit avoir les capacités nécessaires pour la faire. De manière générale un agent doit avoir les trois capacités suivantes même si leurs degrés de perfectionnement peuvent varier dans une large plage selon la nature des agents [MAN 02] :

- a) Capacité de mémoriser et de modifier des connaissances et des intentions et de faire des traitements (calculs et raisonnement) sur celles-ci.
- b) Capacité de réaliser des actions qui peuvent avoir des effets sur les autres agents ou sur l'environnement.
- c) Capacité de percevoir des effets de certaines actions réalisées par l'agent lui même ou par d'autres agents ou par l'environnement.

2.5. Types d'agents

Le type des agents est issu essentiellement de deux courants : l'école cognitive ou social qui tend à générer des systèmes à base d'agents cognitifs et l'école réactive ou biologique qui a généré des systèmes purement réactifs. Une troisième tendance est apparue dans les années 90 pour combiner ces deux aspects dans un même système. Ainsi on se trouve avec trois types d'agents : réactif, cognitif et hybride.

2.5.1. Agent cognitif

Les agents cognitifs possèdent un ensemble de représentations explicites (sur l'environnement, sur les autres agents et sur eux-mêmes) décrits dans une base de connaissances sur laquelle ils peuvent raisonner. Ils réagissent en fonction de leurs connaissances, leurs buts et en fonction des échanges avec les autres agents et de la perception de l'environnement en organisant leurs actions suivant une planification. Ils sont dotés de moyens et mécanismes de communication pour gérer les interactions avec les autres agents (coopération, négociation.) La **Figure 29** présente un modèle d'agent cognitif.

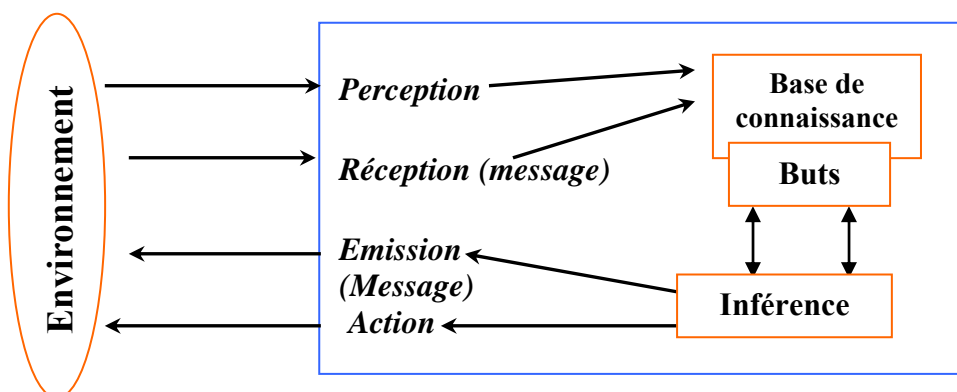


Figure 29: Modèle d'agent cognitif.

2.5.2. Agent réactif

Les agents réactifs sont souvent qualifiés d’être “non intelligents”. Ils sont des composantes très simples qui perçoivent l’environnement et sont capables d’agir sur celui-ci. Ils n’ont pas une représentation symbolique de l’environnement ou des connaissances et ils ne possèdent pas de croyances, pas de mécanismes d’envoi de messages. Leurs capacités répondent uniquement au mode stimulus/action qui peut être considéré comme une forme de communication.

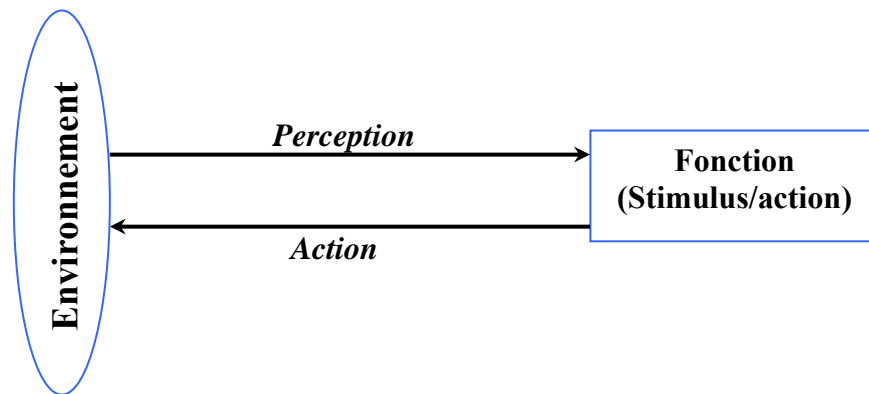


Figure 30 : modèle d’agent réactif.

2.5.3. Agent hybride

C’est un agent qui renferme à la fois l’aspect réactif et cognitif. Selon Feber [FEB 99], il est possible de doter les agents cognitifs de capacités réactives aux événements.

2.6. Agent et objet

La notion d’agent diffère de celle d’objet essentiellement par :

- Les agents sont autonomes alors que les objets ne le sont pas, un agent va décider par son propre processus de décision s’il exécute ou non une action requise.
- Les agents ont leurs propres buts et ils agissent d’une manière pro-active pour atteindre leurs buts (par exemple, ils saisissent des opportunités) alors que les objets ne le font pas.
- Les agents sont dotés d’un comportement social : ils peuvent s’engager dans des interactions complexes, par exemple coopération, compétition, négociation, avec d’autres agents, ce n’est pas le cas des objets.

2.7. Agent et systèmes experts

Les différences essentielles entre un agent et un système expert sont :

- En général un système expert encapsule une expertise ou un ensemble des règles qui déterminent le traitement ou la démarche. Tandis qu'un agent ne reflète pas forcément une expertise.
- La notion de coopération n'existe pas dans les systèmes experts.

2.8. Programmation orientée agents (POA)

La programmation orientée agents a été proposée par Yoav Shoham [SHO 93] comme un nouveau paradigme de programmation, que l'on peut voir comme une spécialisation de la programmation orientée objets (POO). Dans cette approche, les agents sont les éléments centraux du langage, de la même façon que les objets sont centraux pour les langages orientés objets. La perspective sur les agents est cognitive : les agents sont caractérisés par des notions mentales comme leurs croyances, leurs décisions et leurs obligations. En même temps, la programmation orientée agents suppose qu'on va développer des programmes dans lesquels plusieurs agents interagissent, ce qui met l'accent sur la dimension sociale des agents.

3. Les systèmes multi-agents

Les systèmes multi-agents (SMA) se sont développés initialement dans le cadre de l'intelligence Artificielle Distribuée (IAD). Ils appartiennent à la classe des systèmes complexes et s'intéressent particulièrement aux domaines ayant une très forte dynamique.

Ferber [FEB 99] explique la nécessité de *distribuer* l'activité de l'intelligence par les raisons suivantes :

- Les problèmes sont physiquement distribués.
- Les problèmes sont fonctionnellement très distribués.
- Les réseaux imposent une vision distribuée.
- Les systèmes doivent pouvoir s'adapter à des modifications de structure.
- Le génie logiciel va dans le sens d'une conception en terme d'unités autonomes en interaction.

3.1. Définitions

Ferber [FEB 99] définit deux critères selon lesquels un système donné peut être considéré comme un SMA : le système dispose d'agents autonomes fonctionnant en parallèle et cherchant à satisfaire un but ou une fonction de satisfaction. Ces agents possèdent un mécanisme d'interaction de haut niveau indépendant du problème à résoudre (protocole de communication ou mécanismes d'interaction avec l'environnement).

Selon Attoui [ATT 97], un SMA est un système composé d'un ensemble d'entités spécialisées, coopérant pour le compte d'une application globale (fonction globale ou but commun). Ferber [FEB 99], quant à lui, définit le SMA comme étant un système artificiel composé d'une population d'agents autonomes interactifs et coopérant pour aboutir à un but commun et qui se compose des éléments suivants :

- Un environnement E , c'est-à-dire un espace disposant généralement d'une métrique.
- Un ensemble O d'objets qui sont situés, c'est-à-dire que, pour tout objet, il est possible à un moment donné, de lui associer une position dans E qui peut être créée, détruit et modifiée par les agents.
- Un ensemble A d'agents, qui sont des objets particuliers, lesquels représentent les entités actives d'un système.
- Un ensemble de relations R qui unissent les agents entre eux.
- Un ensemble d'opérations permettant aux agents de A de percevoir, produire, consommer, transformer et manipuler des objets de l'ensemble O .

3.2. Caractéristiques des SMA

- a) Chaque agent a des informations ou des capacités de résolution de problèmes limités, ainsi chaque agent a un point de vue partiel.
- b) Le contrôle dans ces systèmes repose sur des protocoles de communication et sur les capacités de raisonnement de chaque agent.
- c) La résolution d'un problème complexe est guidée par la recherche d'un compromis entre plusieurs intelligences ayant chacune des points de vue différents.
- d) La stratégie de résolution des problèmes se construit de façon dynamique de la coopération des agents et de la résolution des conflits qui peuvent se produire.

3.3. Différentes classes des SMA

Les SMA peuvent être conçus selon plusieurs types d'architectures. Le choix de l'architecture aura beaucoup d'impact sur le niveau de complexité de la modélisation, du développement et surtout de l'implémentation du système. En effet, les architectures qui tendent vers la décentralisation se modélisent plus difficilement. La plus grande difficulté de ces architectures est leurs implémentations. D'un autre côté, les systèmes adoptant une architecture plus centralisée (ou hiérarchisée) sont relativement plus simples à concevoir. Les architectures présentées ici sont les plus utilisées mais elles ne sont pas uniques. En effet, il

existe plusieurs autres architectures hybrides empruntant quelques caractéristiques à plusieurs architectures.

3.3.1. Le système Tableau noir

Les systèmes centralisés se basent sur un concept assez simple et puissant, le partage des données. Dans ces systèmes, les agents ne se communiquent pas directement les données entre eux. Ils envoient et obtiennent les données à partir tableau (*board*). Cette structure permet aux agents d'échanger les données utiles à l'exécution du programme et de les garder dans une structure accessible à tous. Cette architecture possède trois sous systèmes : KS (*Knowledge Source*) qui sont en fait les agents du système, le tableau qui garde et partage les données pour les agents ainsi qu'un contrôleur qui gère les conflits d'accès aux ressources entre les agents.

L'inconvénient majeur de ce type d'architecture est l'inefficacité de ces systèmes, comme toutes les données sont gardées sur la même machine, le manque d'espace mémoire devient souvent un problème [BRI 01]. D'un autre côté, lorsque plusieurs agents tentent d'accéder aux mêmes données, un problème de partage des ressources est inévitable.

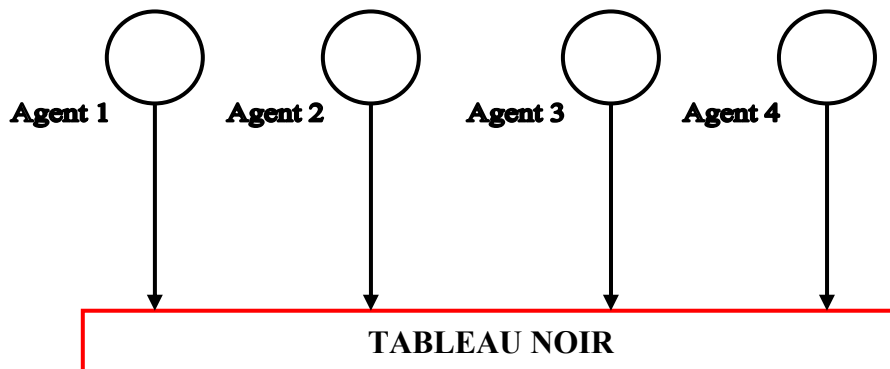


Figure 31 : Système Tableau noir (*blackboard*).

3.3.2. Les systèmes hiérarchisés

Ces systèmes se basent sur une structure où les entités répondent à leurs supérieurs hiérarchiques. Ce type de système est relativement simple à implémenter. Plusieurs systèmes utilisent cette architecture pour la réalisation des SMA.




Figure 32: Système Hiérarchique.

3.3.3. L'approche totalement distribuée

Cette approche est de loin la plus puissante mais aussi la plus complexe à développer et à implémenter. L'approche consiste à diviser le SMA en sous-systèmes indépendants effectuant chacun une partie du travail. Chaque sous-système est constitué d'un ou plusieurs agents pouvant effectuer une ou plusieurs tâches. Ces agents peuvent avoir un but auxiliaire ou tout simplement attendre des requêtes provenant des autres agents leur demandant d'effectuer une ou des tâches en particulier.

L'approche distribuée procure de grands avantages comme, le partage équitable du travail entre les sous-systèmes et/ou agents, l'utilisation plus uniforme des ressources, l'indépendance et l'autonomie des sous-systèmes, la répartition des tâches, l'efficacité du modèle concurrent et/ou parallèle, leur grande extensibilité ... etc.

Il existe peu de systèmes totalement distribués étant donné leurs complexités de développement et d'implémentation. Le développement d'un système distribué demande la résolution de plusieurs problèmes comme la façon de communiquer entre les sous systèmes, les moyens utilisés pour déterminer l'affectation des tâches, la connaissance mutuelle des sous-systèmes et de leur environnement, la synchronisation et la coordination des actions des agents et des différents sous systèmes ... etc [BRI 01].

3.4. L'interaction dans les SMA

Différents éléments sont examinés dans le comportement d'un SMA : les interactions avec l'environnement, la communication entre agents, et l'organisation de la société.

L'interaction est une notion très importante dans les domaines des systèmes multi- agents, en effet, elle permet d'augmenter la capacité du groupe à atteindre un objectif commun. D'après Ferber [FEB 99], elle peut être définie comme la mise en relation dynamique de deux ou plusieurs agents par le biais d'un ensemble d'actions réciproques. Les situations d'interactions sont nombreuses et diverses : L'échange de données entre serveurs

informatiques, l'aide d'un robot à un autre, la mise en commun des compétences de plusieurs spécialités pour porter un diagnostic...etc.

3.4.1. Notion d'auto-organisation

Une organisation est définie comme une structure décrivant comment les membres (Agents) de l'organisation sont en relation et interagissent afin d'atteindre un but commun. L'auto organisation d'un système consiste en la transformation de la *topologie* (c'est-à-dire des connexions du réseau) de ses parties.

3.4.2. Notion de coopération

D'après l'équipe SMAC (Systèmes Multi Agents Coopératifs), la *coopération idéale* doit satisfaire les trois points suivants:

- Tout signal doit être *interprété sans ambiguïté* par l'agent qui le reçoit (point de vue de la perception).
- L'information (signal interprété) doit être informative (point de vue de la déduction).
- Les résultats et les conclusions d'un agent doivent être utiles aux autres agents et/ou à l'environnement (point de vue de l'action).

A l'opposé, une situation est dite *non coopérative* si au moins l'un des trois points précédents n'est pas satisfait. Nous présentons maintenant différentes notions liées à des situations de non coopération : [FEB 99]

a) L'incompétence

L'incompétence correspond au cas où un agent perçoit un signal qui lui est non interprétable ou ambigu. Elle est détectée par l'agent lorsqu'il ne peut pas extraire un contenu informatif du message. Cela provient de la croyance erronée de l'agent émetteur sur les compétences de l'agent destinataire. Dans cette situation, l'agent récepteur doit retransmettre ce signal (le signal ne lui est pas destiné) à d'autres agents pour qui il pense qu'il sera informatif. Dans le cas où il ne trouve pas à qui le retransmettre, l'agent récepteur le retourne.

b) L'improductivité

Un agent détecte une *improductivité* lorsque le signal perçu/reçu est interprété (compris) mais ne le conduit pas à agir pour accomplir sa tâche. Elle provient lorsque l'agent n'a pas à sa disposition toutes les ressources nécessaires pour accomplir sa tâche. A sa détection l'agent cherche à retransmettre le message (signal) à d'autres agents qui, si cette recherche échoue, il le retourne le message à l'agent émetteur.

c) *L'inutilité*

L'inutilité est le cas où les résultats ou conclusions d'un agent ne sont pas utiles à autrui ou à l'environnement. Celle-ci est détectée lorsqu'un agent transmet ses résultats aux autres agents qui, à leur tour, lui renvoient le message transmis (pas d'agent intéressé).

Cette inutilité met en évidence deux situations non coopératives : le *conflit* et la *concurrence*

▪ *Le conflit*

Cette situation provient lorsque plusieurs agents tentent d'accéder, en même temps, à des ressources ou informations communes non partageables (ce qui mène généralement à des inter blocages). Il est détecté par un agent lorsqu'il reçoit un message qui n'est pas ambigu, mais opposé à ses propres conclusions. Dans le cas du traitement d'images, la situation de conflit provient surtout lorsque plusieurs agents tentent de modifier une même image.

▪ *La concurrence*

En situation de concurrence l'agent croit qu'un autre agent va aussi aboutir au même état. Dans ce cas, l'agent va chercher un nouvel état lui permettant d'éviter la concurrence en se coordonnant avec l'autre agent concurrent. Celle-ci survient lorsqu'un autre agent a déduit les mêmes résultats que les siens ou encore qu'un autre agent cherche à atteindre les mêmes buts que lui.

3.4.3. Notion d'adaptation

L'adaptation est également une notion importante en intelligence artificielle. En traitement d'images, elle permet de prendre en compte la variabilité des situations et les mesures imprécises ou bruitées. Parmi les diverses définitions données, citons celle énoncée par Ferber [FEB 99], qui la définit comme une caractéristique individuelle des agents, et on parle alors d'*apprentissage*, elle peut être aussi définie comme étant la sélection et le paramétrage automatique des méthodes utilisées. Cette dernière définition est bien adaptée au cas du système d'interprétation d'images à architecture multi agents. Un agent est *adaptatif* si, au-delà de son comportement de base prévu, il sait prendre en compte le contexte de la situation, au moment de l'exécution, pour mettre en oeuvre le traitement le plus pertinent.

3.4.4. La communication

La communication est un élément très important dans les systèmes multi agents. En effet, sans la communication les agents ne peuvent pas coopérer, coordonner leurs actions et réaliser les tâches en commun. Des langages de communication sont utilisés pour contrôler et

structurer les échanges d'informations entre les agents, de façon à *réduire le temps de communication* et la *quantité d'informations échangées*.

On trouve plusieurs types de communications [Rus 97] dans une structure organisationnelle, à savoir :

- La communication pour établir la coordination.
- La communication utilisée pour la transmission des données concernant les mécanismes de résolution de problèmes.
- La communication qui sert de stimuli pour les agents.
- La communication qui est utilisée pour fournir les résultats.

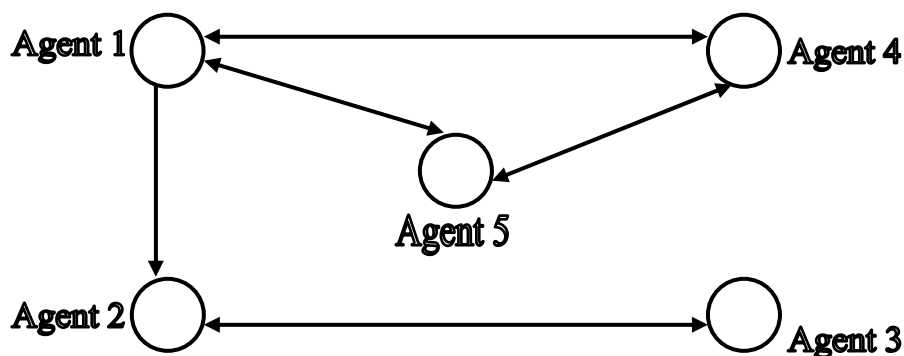


Figure 33 : Communication par délégation.

3.4.5. La négociation

La négociation peut être aussi définie comme étant un principe de communication qui met tous les participants sur un pied d'égalité. Chaque élément peut proposer et recevoir des avis ou des informations au reste des participants. Chaque individu décide seul de son comportement vis-à-vis de données reçues. Tous ces échanges se déroulent en parallèle sans intervention ou de contrôle extérieur.

4. Apports des SMA pour la segmentation d'images

Les agents fournissent un cadre « naturel » pour l'expression de la coopération et de la négociation. Les SMA permettent de faire cohabiter des agents de toutes natures, depuis des agents réactifs jusqu'à des agents cognitifs évolués, et de les faire évoluer en parallèle. Ces considérations ont conduit à concevoir et à étudier différentes *architectures logicielles* ces architectures doivent proposer des solutions pour :

- Représenter et organiser les informations manipulées par le système afin de faciliter sa gestion.

- Extraire (apprendre) de nouvelles informations
- Focaliser et combiner les différents traitements nécessaires à l'interprétation des images.
- Contrôler et coordonner l'exécution de ces traitements, c'est-à-dire décider à quel moment, sous quelles conditions et dans quel ordre ils doivent être déclenchés.

Un état de l'art de ces différents aspects est présenté notamment dans [BOU 99] et [GAR 00].

4.1. Représenter et organiser les informations

4.1.1. L'hétérogénéité des informations manipulées

D'après [PIT 90], les informations qui, parmi toutes les informations disponibles, sont utilisées dans les processus de décision sont désignées sous le terme de connaissances. Selon le contexte et les étapes du processus de segmentation, une information peut donc devenir ou non une connaissance. Parmi les connaissances, on peut distinguer les connaissances opératoires qui permettent de définir les actions à entreprendre, les connaissances descriptives données *a priori*, ou les informations produites pendant le processus d'interprétation qui sont utilisées, à une étape de traitement donnée, pour produire de nouvelles informations.

4.1.2. La représentation et l'organisation des informations

La façon d'associer les différentes informations entre elles est un problème clé. Les premières représentations des informations se caractérisaient souvent, comme le préconisait Marr [MAR 82], par la distinction de plusieurs niveaux, c'est-à-dire essentiellement d'un bas niveau, de niveaux intermédiaires et d'un haut niveau. La difficulté était alors avant tout d'intégrer harmonieusement les traitements opérant à chaque niveau. On s'attache en effet à multiplier les niveaux de représentation de l'information en particulier dans le bas niveau, tout en s'efforçant de diminuer l'écart entre bas et haut niveau, par des interprétations qualitatives précoces, qui augmentent les possibilités de raisonnement du système. Pour segmenter une image, le système a en effet souvent besoin de connaissances de haut niveau pour effectuer ses traitements de plus bas niveau, alors que ces connaissances sont la plupart du temps elles-mêmes le résultat de traitements, et ne sont pas nécessairement disponibles immédiatement, d'où la recherche de meilleurs interconnexions entre les niveaux de représentation.

Des représentations sous forme de réseaux sémantiques et de graphes ont été utilisées, car elles permettent de formaliser les liens existant entre connaissances. Il est ainsi possible de représenter simultanément les objets (les noeuds) et les opérateurs (les arcs), ou de définir des

liens de composition/spécialisation voire de relation spatiale (sur les arcs) entre objets (les noeuds), tout en ayant la possibilité d'attacher des listes de méthodes aux noeuds.

Les choix des modes de représentation des informations s'effectuent donc en fonction de deux objectifs, d'une part intégrer de la façon la plus riche possible les informations (créer des liens), d'autre part préserver leur accessibilité, et faciliter leur partage, afin notamment de permettre la formalisation de contexte d'exécution pour les opérateurs et de favoriser les capacités de raisonnement du système, les SMA répandent bien à ces objectifs [GER 99].

4.2. Extraire et gérer de nouvelles informations (apprendre)

4.2.1. L'extraction de nouvelles informations

Les informations manipulées par le système sont soit fournies *a priori* par le concepteur (informations génériques ou spécifiques du domaine d'application) ou par un module d'apprentissage, soit acquises par le système lui-même en cours d'exécution. Ces informations concernent par exemple des éléments de la description de l'image ou les paramètres des modèles qui doivent être estimés.

4.2.2. Segmentation d'image, un processus incrémental

Le problème de segmentation est souvent posé comme un problème *incrémental* de collecte d'informations. Au cours du processus de segmentation, les informations doivent être accumulées de manière incrémentale (affinement de la segmentation), afin d'augmenter progressivement les possibilités de déduction du système (ses connaissances) et d'adapter constamment les traitements en fonction des informations déjà récoltées.

4.3. Focaliser et combiner les traitements

4.3.1. Segmentation d'image, un processus distribué

La segmentation d'image est un processus distribué en termes de buts à atteindre, de zones de l'image à explorer et de méthodes à appliquer. Différents traitements doivent être combinés afin de segmenter une image, qui sont chacun focalisé dans un espace à trois dimensions, caractérisés par les questions suivantes : la question du « où », c'est-à-dire du choix de la zone de l'image à explorer, la question du « quoi », c'est-à-dire du choix des informations à rechercher et la question du « comment », c'est-à-dire du choix des algorithmes, des méthodes et des stratégies à utiliser [GAR 00]. Chaque traitement utilise un certain nombre d'informations (de connaissances) organisées suivant cet espace tridimensionnel pour produire de nouvelles informations.

4.3.2. Segmentation d'image, un processus coopératif

La distribution des traitements va de pair avec la mise en oeuvre de *coopérations* par le système, qui doit combiner plusieurs sources d'informations ou modalités de traitement pour accomplir une tâche donnée, et tirer parti, par exemple, des complémentarités entre méthodes ou opérateurs et augmenter la robustesse du processus de segmentation. Un état de l'art peut être trouvé dans [GAR 00].

La coopération confrontative concerne les différents types de fusion de données [BLO 96] qui sont effectués soit entre des données issues de plusieurs capteurs, soit entre différentes résolutions, différents instants, modes de traitement ou niveaux d'analyse, soit entre des données externes (cartes, atlas, schémas, images déjà interprétées). Ces types de fusion peuvent impliquer des événements survenant à des instants différents (fusion temporelle) ou concerner des solutions conflictuelles à un problème fournies par plusieurs opérateurs, et analysées par des techniques de fusion.

4.4. Contrôler et coordonner les traitements

4.4.1. Définition de la notion de contrôle

Le contrôle dans un système de segmentation est défini dans [GAR 00], comme «*l'ensemble des procédures, mécanismes et stratégies qui permettent d'orchestrer les traitements en vue de progresser vers le but recherché, c'est-à-dire de choisir à chaque pas de la résolution l'entité à activer* ». C'est un problème central dans les systèmes de vision, où on ne connaît pas *a priori* la chaîne de traitements qui permet de résoudre le problème posé. Le choix de cette chaîne de traitements dépend en effet du contexte et des situations rencontrées.

4.4.2. Coordination des traitements

La nature distribuée du processus de segmentation (distribution spatiale, opératoire, ...) fait naître des besoins de coordination des traitements et de maintien de la cohérence entre les informations et traitements locaux et globaux. Le contrôle peut pour cela être centralisé ou décentralisé, selon que les décisions sont prises globalement par un coordinateur central ou localement par différents acteurs autonomes en interaction (Agents). La décentralisation du contrôle est notamment un moyen pour mettre en oeuvre une stratégie réactive et opportuniste. Les systèmes multi-agents permettant de mettre en oeuvre un contrôle décentralisé.

Du point de vue du génie logiciel, les SMA permettent :

- **Préserver la modularité** : c'est une préoccupation visant à contrôler la maintenabilité du système tout en garantissant la capacité d'améliorer ou d'ajouter de nouveaux agents, sans dégrader les performances du reste du système ou provoquer le besoin d'une réécriture massive du code. La modularité permet de réduire la complexité du problème, donc facile à développer, à tester et à maintenir le système.
- **La flexibilité** : comme souligne Boissier dans [Boi 04], le contrôle doit être suffisamment flexible pour permettre, d'une part, une évolution en fonction des agents présents et, d'autre part, installer dynamiquement des boucles de contrôle entre eux.
- **Robustesse** : comme l'ont montré les approches coopératives en segmentation d'images, une certaine robustesse peut être obtenue en fusionnant l'analyse de plusieurs agents.
- **Réutilisabilité** : un agent peut être réutilisé par un autre système sans revoir son expertise.

5. Les approches multi-agents proposées pour la segmentation

5.1. Image de type quelconque

Différents systèmes multi-agents ont été proposés pour l'extraction de caractéristiques bas niveau (de primitives de formes) [LIU 99], [BEL 98], [DUC 01] ou pour l'interprétation à base de connaissances de scènes complexes [BOU 99], [EAL 01]. Ces systèmes sont généralement destinés à des applications spécifiques, qui ont pour objectif de traiter, d'interpréter et d'analyser des images ayant des caractéristiques propres nécessitant des opérateurs, des modèles et des traitements adaptés. Parmi ces architectures, certaines sont composées d'agents cognitifs [Boi 93], qui gèrent généralement des modules distincts et hétérogènes de traitement, collaborant pour l'interprétation de l'image, tandis que d'autres sont composées d'agents réactifs, hybrides ou situés [LIU 99], [EAL 01] où l'accent est d'avantage porté sur le positionnement des agents dans l'espace de l'image et sur les entités symboliques recherchées.

Dans [Boi 93], l'auteur propose ainsi un système d'agents cognitifs, dans lequel les agents ont la possibilité de raisonner et de définir leurs propres buts et sont organisés de façon explicite au moyen de structures de coordination. Cette architecture générique a pour but l'étude du contrôle dans un système intégré de vision [CRO 93].

Le système se décompose en sous-systèmes, dédiés à la construction de la description de la scène à un niveau de représentation donné et correspond à un agent du système global. Un

agent peut-être défini par son niveau (sur un plan vertical qui donne un agent-niveau), par son focus (sur un plan horizontal qui donne un agent focus) ou par l'intersection des deux (appelé agent de base). Le contrôle est essentiellement descendant, c'est-à-dire que les agents d'un niveau supérieur commandent ceux des niveaux inférieurs. Les règles régissant les interactions entre les agents, travaillant au même niveau de représentation (intra-niveaux) ou de niveaux différents (inter-niveaux), doivent être bien définies afin de contraindre et de cibler les traitements du système.

[LEF 94] a également proposé un système multi-agents pour la vision, dans le cadre d'une application de photo-interprétation militaire, où les agents gèrent des modules expert de traitement. Chaque agent y possède une expertise qui repose sur l'estimation *a priori* de la capacité de l'agent à résoudre le problème posé (score d'aptitude), sur le contrôle des paramètres d'exécution que peut effectuer l'agent (adaptation de ses paramètres internes) et sur l'analyse *a posteriori* de la qualité d'un résultat (score de réussite). Cette expertise permet à l'agent, dans sa couche de contrôle, d'évaluer sa pertinence à répondre à une requête extérieure, de déterminer les valeurs de traitements correspondantes et d'établir un compte-rendu final sur la qualité du résultat.

Dans [BOU 99], une société d'agents situés est développée pour segmenter et analyser une séquence d'images de cellules en mouvement. Chaque agent est ancré à une position donnée de l'image, avec un but donné (segmenter une partie de la cellule par exemple son noyau ou son cytoplasme). Ils sont spécialisés à l'aide de connaissances *a priori* sur les objets à segmenter et dotés de plusieurs comportements, de perception (d'exploration et de marquage de l'image par croissance de région), d'interaction (de négociation pour fusionner les régions) et de reproduction (dans la même image et dans les images suivantes de la séquence temporelle).

Dans [EAL 01], une architecture multi-agents est proposée pour la reconnaissance automatique de cibles militaires. Les agents y sont situés, spécialisés en fonction de leur localisation sur l'image, des objets de la scène à décrire et en fonction de leur but (localisation, détection, reconnaissance et identification).

5.2. Image IRM

Certaines approches, reposent sur l'introduction d'agents très simple et réactifs, qui sont situés dans l'image, considérée pour eux comme un environnement qu'ils doivent explorer et sur lequel ils déposent des marques, les étiquettes formant l'interprétation de l'image. Dans le système proposé par [LIU 99], des agents réactifs sont conçus pour étiqueter des structures

finies et homogènes, comme le cortex cérébral. Ces agents sont dotés de différents comportements, de perception, d'étiquetage, de reproduction et de diffusion.

[BEL 98] a développé un système coopératif pour la segmentation « bas-niveau » des images. Dans ce système, une image est segmentée par une multitude d'agents indépendants mettant en oeuvre des processus de croissance de région ou de suivi de contour. Chaque processus est initialisé à un endroit précis de l'image, avec un germe, et il fait croître sa primitive à partir de cet endroit. La croissance (région ou contour) s'effectue par une évaluation multi-critères des pixels avoisinants et sélection des meilleurs candidats. Lorsqu'un processus manque d'informations pour mener à bien les décisions qu'il doit prendre, il crée de nouveaux processus, qualifiés de fils pour segmenter de nouvelles primitives et ainsi récolter plus d'information dans l'environnement.

[DUC 01] propose une société d'agents organisée selon une pyramide irrégulière où des agents région et des agents contour collaborent pour segmenter une image (par exemple une image IRM). Les agents régions sont rattachés à des partitions de l'image obtenues par un algorithme de division tandis que les agents contours sont rattachés à des chaînes robustes de contours extraites après calcul du gradient de niveaux de gris. Les agents régions sont dotés de différents comportements d'extraction des régions, d'exploration pour identifier leurs voisins, de planification de fusion avec les autres agents régions, de coopération avec les agents contour pour décider de la fusion des régions, et de destruction/reproduction pour créer des agents à des niveaux supérieurs de la pyramide.

L'approche décrite dans [HAR 04] propose un système multi-agents basé sur une approche de segmentation floue \ croissance de régions appliquée à des IRM cérébrales.

Dans [SEM 06] les auteurs proposent une approche floue possibiliste implémentée dans un SMA qui a donné de bons résultats lors de la classification des structures cérébrales (Matière grise, blanche, LCR) mais le système multi-agents n'a pas marché (problème d'implémentation).

Laurence dans [GER 99] a distribuer les tâches de segmentation sur trois agents spécialisés, un *agent_matière grise* pour segmenter la matière grise, *agent_matière blanche*, et *agent_LCR*.

Conclusion

Nous avons vu, tout le long de ce chapitre que les SMA sont des systèmes idéaux pour représenter des problèmes possédant de multiples méthodes de résolution et/ou de multiples perspectives. Ces systèmes disposent les avantages traditionnels de la résolution distribuée et

concurrente de problèmes (modularité, vitesse, fiabilité...etc). Ils héritent aussi des bénéfices envisageables de l'intelligence artificielle comme la facilité de maintenance, la réutilisation et la portabilité.

Dans le contexte de la segmentation des IRM cérébrales, les systèmes multi-agents ont montré leur efficacité lorsque plusieurs méthodes interviennent (coopèrent), donc l'utilisation d'une approche coopérative pour segmenter des IRM.

Dans la suite de ce mémoire nous allons présenter l'approche proposée, et nous justifions le choix des outils et les paramètres de chaque algorithme.

CHAPITRE V : Approches proposées, implémentation et réalisation.

Introduction

Les différentes méthodes et techniques de segmentation d'images cérébrales ont été présentées dans les sections précédentes, où nous avons vu que la coopération des classifieurs apporte une solution plus riche qui tire partie des avantages de chaque classifieur.

Dans cette partie nous allons présenter notre approche, qui consiste à faire la coopération entre l'algorithme flou FCM et l'algorithme possibiliste PCM.

L'architecture des agents, les choix des paramètres de chaque algorithme seront détaillés le long de ce chapitre.

1. Choix de l'algorithme

1.1. Quel type de méthode ?

Nous devons tout d'abord préciser si l'algorithme doit être supervisé ou non. L'emploi d'un algorithme supervisé nécessite, comme nous l'avons vu dans le deuxième chapitre (cf II.3.3.2), une base d'apprentissage pour chaque classe et pour chaque patient. Cela constitue un premier inconvénient de ce type de méthodes [BAR 99]. Pour notre approche, puisque nous aurons dans la suite à segmenter des images IRM de différentes modalités, et la création de cette base peut s'avérer fastidieuse pour les experts. De plus, les méthodes supervisées en segmentation d'images médicales peuvent être très dépendantes de la base d'apprentissage [BAR 99]. Clarke *et al.* [CLAR 93] ont par exemple comparé les méthodes de KPVV avec réseau de neurones sur la segmentation d'images IRM de cerveau et ont remarqué que les différences entre les segmentations sont faibles lorsque les tissus sont bien différenciés par leurs paramètres.

Plus généralement, de nombreux auteurs notent que des petites différences dans le jugement de l'expert lors de la phase d'apprentissage peuvent causer de grandes variations dans les résultats, ce qui rend les méthodes supervisées inadaptées pour des études quantitatives en particulier lorsque la base d'entraînement est mal adaptée [PHI 95].

L'intérêt des méthodes non supervisées est qu'elles ne nécessitent aucune phase d'apprentissage ou d'étiquetage manuel préalable. La seule intervention de l'expert se situe à la fin du processus pour identifier les classes calculées avec les classes biologiques.

Ces raisons nous ont fait préférer une méthode non supervisée, et parmi cette classe d'algorithme, nous nous sommes intéressés aux algorithmes de classification.

1.2. C-moyennes floues ou algorithme possibiliste ?

L'algorithme de référence utilisé aujourd'hui dans de nombreux domaines [MEN 98], est celui des c-moyennes floues (FCM). Di Gesu et Romeo [DIG94] ont comparé la segmentation d'images IRM obtenue à l'aide de 4 algorithmes non flous (analyse d'histogramme, k plus proches voisins, méthode de division/fusion et partitionnement simple) et ont déduit que la classification non floue est mal adaptée dans le cas où les nuages de points se chevauchent ou lorsque l'information disponible est vague et incertaine, ce qui est le cas des images utilisées dans notre recherche.

Nous indiquons dans ce paragraphe les raisons pour lesquelles nous avons opté pour l'algorithme de classification possibiliste aux plus classiques C-moyennes floues. Les arguments portent à la fois sur l'interprétation des degrés d'appartenance et sur l'étude des distributions de possibilité des tissus générées par les deux méthodes.

1.2.1. Interprétation des degrés d'appartenance

- *FCM et degrés d'appartenance relatifs*

La contrainte de normalisation (2.11) utilisée pour la minimisation de la fonctionnelle (2.12) est source d'erreur dans l'interprétation des degrés d'appartenance issus du FCM. Krishnapuram et Keller [KRI 96] donnent une série d'exemples simples qui illustrent les problèmes associés à cette contrainte, que nous résumons dans la **Figure 34**.

Cette figure présente deux nuages de points avec deux points aberrants **A** et **B**. L'algorithme des C-moyennes floues appliqué à deux classes ($C=2$) avec un degré flou fixé à $m=2$. Les degrés d'appartenance de chaque point aux deux classes sont présentés dans le **Tableau 2**.

Points	A		B		C		D	
u_{ij} FCM	0.53	0.47	0.52	0.48	0.62	0.38	0.82	0.18

Tableau 2 : Degrés d'appartenance générés par le FCM sur l'exemple

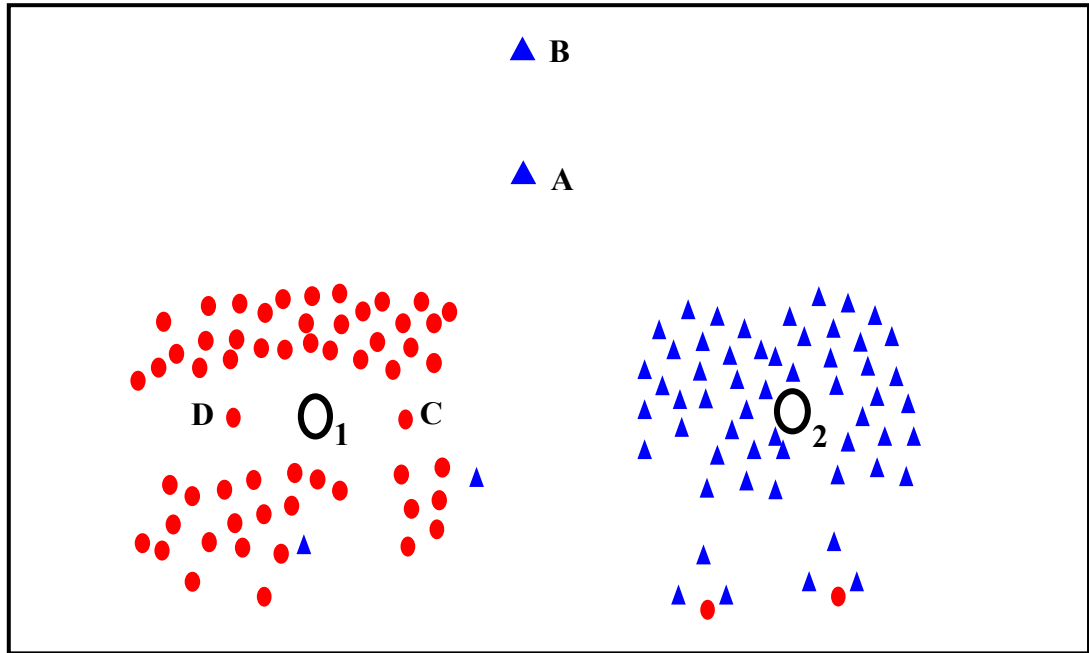


Figure 34 : Démonstration de la mauvaise interprétation des degrés d'appartenance du FCM

Une analyse des résultats du **Tableau 2** montre que :

- Les points **A** et **B**, résultant par exemple d'une erreur de mesure ou d'un bruit, ne doivent pas avoir des degrés d'appartenance significatifs aux deux classes. De plus, les degrés d'appartenance de **B** doivent être plus faibles que ceux de **A**, ce point étant encore plus éloigné des classes. Néanmoins, en dépit de ces considérations intuitives, la contrainte (2.11) impose aux degrés d'appartenance de **A** et **B** des deux classes d'être approximativement égaux à 0.5.
- Les degrés d'appartenance des points **C** et **D**, tels qu'ils sont calculés par FCM, sont significativement différents alors que ces deux points sont approximativement à la même distance du centre de la classe de gauche. Cela est encore dû à la contrainte de normalisation (2.11) qui force **C** à partager un peu de son degré d'appartenance à la classe de droite, dont il est plus proche que **D** ne l'est.

Ces exemples simples montrent que les degrés d'appartenance U_{ij} générés par les C-moyennes floues sont des degrés relatifs, dépendant non seulement de l'appartenance du vecteur j à la classe i , mais aussi à toutes les autres classes $k \in \{1 \dots C\} \setminus \{i\}$. Cela s'observe d'ailleurs dans l'expression (2.13). Les réels U_{ij} générés par le FCM ne sont donc pas représentatifs, ils expriment plutôt un degré de partage des vecteurs dans toutes les classes. Ils ne peuvent pas, de plus, distinguer entre un point au bord des classes et un point aberrant (exemple des points **A** et **B**).

- *PCM et degrés d'appartenance absolus*

La valeur de U_{ij} dans (2.17) ne dépend maintenant que de la distance du vecteur X_j à la classe i . Les degrés d'appartenance générés par PCM ne sont ainsi plus des degrés relatifs ou de partage, ils deviennent des valeurs absolues «*typicality*» [KRI 96] reflétant la force avec laquelle chaque vecteur appartient à toutes les classes. L'application de l'algorithme de classification possibiliste sur le même ensemble de données, donne les résultats présentés dans le **Tableau 3**.

Points	A		B		C		D	
u_{ij} FCM	0.53	0.47	0.52	0.48	0.62	0.38	0.82	0.18
u_{ij} PCM	0.26	0.18	0.09	0.06	0.77	0.13	0.76	0.07

Tableau 3 : Comparaison des degrés d'appartenance générés par FCM et PCM

Les degrés d'appartenance générés par PCM reflètent de manière plus exacte la réalité de la distribution des points : **A** et **B** se voient affecter des degrés d'appartenance faibles aux deux classes. **C** et **D** ont un degré d'appartenance par rapport la première classe quasi identique.

1.2.2. PCM et imagerie par résonance magnétique

Les images médicales présentent des caractéristiques qui ne sont pas compatibles avec une représentation des degrés d'appartenance en degrés de partage. En raison de la nature complexe des interfaces entre tissus (MB/MG et MG/LCS par exemple), un nombre significatif de pixels (mixels) contient un mélange de deux ou trois tissus. En reprenant la contrainte (2.11) qui impose aux U_{ij} peut causer des erreurs d'interprétation (cas des points **C** et **D** de la **Figure 34**), nous préférons dans ces cas-là un calcul de degré d'appartenance absolu. De plus, les images IRM sont affectées par un bruit inhérent à la méthode d'acquisition et aux méthodes de reconstruction que PCM semble mieux gérer. Pour ces deux raisons principalement, nous nous sommes orientés vers l'algorithme de classification possibiliste pour caractériser les tissus cérébraux.

1.2.3. Limites du FCM

Un grand nombre d'algorithmes est dérivé du FCM, utilisant des métriques différentes ou des prototypes de dimensions supérieures. Citons les FCV (*fuzzy c-variétés*), FCE [BEZ 81] (*fuzzy c-elliptotypes*), AFC [DAV 92] (*adaptive fuzzy c-elliptotypes*), Le FCM et ses algorithmes dérivés souffrent de plusieurs inconvénients :

- 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 fonctions d'appartenance construites sont donc interdépendantes. Aussi, les estimations des centres des classes ne correspondent pas aux centres réels ou typiques [MEN 98].
- Les points aberrants (éloignés) peuvent avoir des valeurs d'appartenance élevées et ils peuvent affecter de façon significative l'estimation des centres des classes.
- Ces algorithmes modélisent dans la phase de classement l'hésitation ou l'ambiguïté entre classes à partir de règles de décisions floues fixées *a priori* [MEN 98]. Dans la phase de classification, les points ambigus ou non représentatifs des classes peuvent alors affecter la position des centres.

Pour remédier aux problèmes des FCM, nous proposons d'inclure la notion de rejet d'ambiguïté et d'aberrance pour bien initialiser les centres de classes définis par (2.14).

1.2.4. Le Rejet d'ambiguïté [MEN 98]

Pour réduire un taux d'erreurs excessif dû au bruit et aux autres facteurs d'incertitude inhérents aux mesures réelles, le rejet d'ambiguïté apporte une solution intéressante .

En classification, un individu X_k localisé trop loin d'une classe doit avoir une faible valeur d'appartenance par rapport à cette classe. Dans le but de réduire le risque de mauvaise classification, le rejet d'aberrance est utilisé pour éviter de classer cet individu. Dans la littérature, les règles proposées dans le but de rejeter ces individus, sont le plus souvent basées sur des valeurs de seuil lors de l'étape de décision ou (une valeur de seuil pour chaque classe par exemple) et non dans l'étape de classification.

Cette approche apporte des améliorations par rapport au FCM classique parce que :

- Les rejets sont calculés dans l'étape de classification et non dans l'étape de décision, les données aberrantes ou ambiguës sont alors moins prises en compte dans la détermination des centres.
- L'algorithme inclut une modélisation de l'hésitation ou de l'ambiguïté, et les fonctions d'appartenance sont affectées à tous les sous-ensembles de classes de $2^c - 1$ plutôt qu'aux éléments de C seulement.
- Les notions de rejet conduisent à attribuer une fonction de pondération différente à chaque individu selon que celui-ci appartient clairement à une classe, à aucune ou bien à plusieurs classes de façon égale.
- L'apport essentiel de l'algorithme est qu'il permet d'inclure une modélisation de l'ambiguïté et de l'ignorance en affectant des fonctions d'appartenance à tous les sous-

ensembles. Il s'agit d'une approche particulièrement riche et souple, qui est capable de s'adapter à un très grand nombre de situations.




Figure 35: La partition de l'espace de représentation. (a) : Espace de représentation simple, (b) : espace de représentation avec concept d'ambiguïté.

Remarque

Dans la **Figure 35 (b)**, la classe C_{123} est la nouvelle classe qui contient le mélange des individus aberrants des classes C_1, C_2, C_3 . Cette nouvelle classe et les autres classes ambiguës influent sur le calcul des centres de classes du FCM.

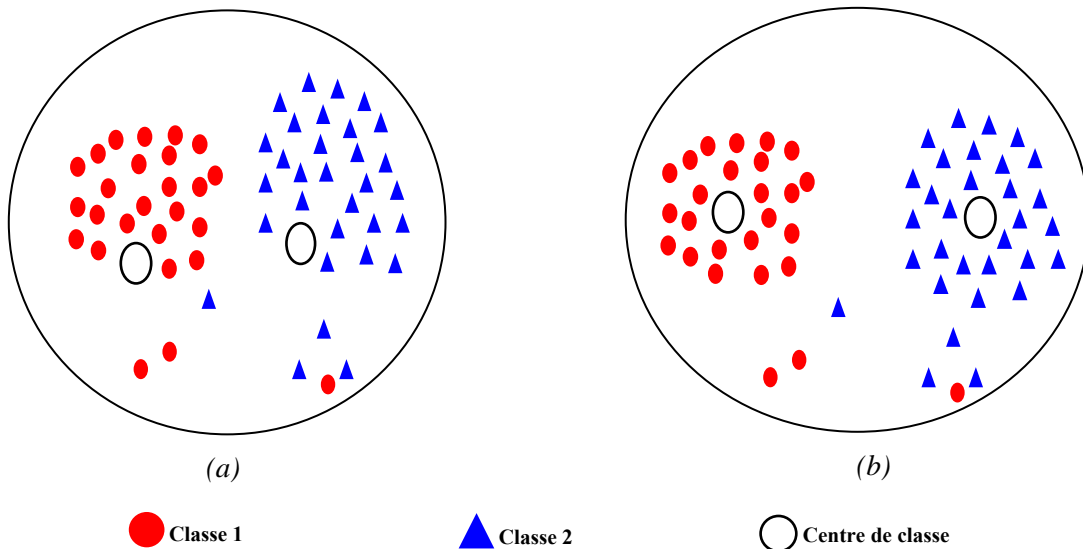


Figure 36: influence des points aberrants sur les centres des classes. (a) : Classification floue classique. (b) : Classification floue avec rejet des points éloignés.

La **Figure 36** illustre l'influence des points éloignés (résultants, par exemple, d'une erreur de mesure ou d'un bruit) sur la position des centres de classes. Avec la classification floue (algorithme comme le FCM ou une de ses variantes), on remarque, que les points éloignés (**Figure 36 (a)**) par rapport aux centres des classes, vont être pris en compte lors de la phase de classification, c'est la cause principale du décalage des centres des *classe1* et *classe2* par

rapport aux nuages des points. Contrairement aux points de la **Figure 36 (b)** où la notion de rejet des points éloignés a été introduite, pour remédier au problème précédent. Dans ce cas là, les centres de classes se trouvent aux milieux des nuages des points.

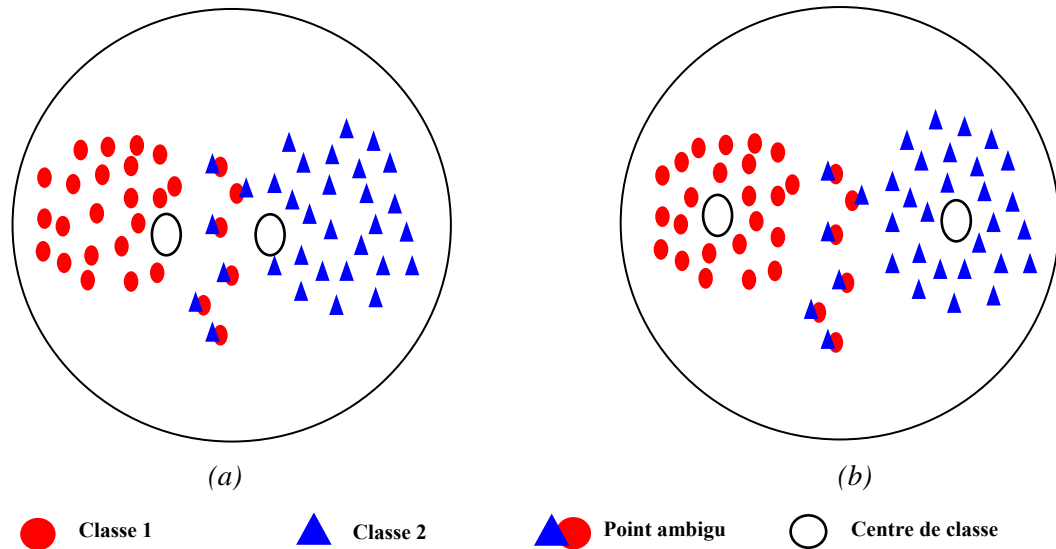


Figure 37 : influence des points ambigus sur les centres des classes. (a): Classification floue classique. (b): Classification floue Avec rejet des points ambigus

Quant à la **Figure 37**, elle illustre bien l'influence des points ambigus (mélange de classe) sur les centres des classes où les centres se trouvent proches les uns des autres (voir **Figure 37 (a)**), mais lorsqu'on classe ces points où le concept de rejet est introduit, on remarque que les centres prennent une position optimale (**Figure 37 (b)**).

Remarque :

Un individu est considéré comme ambigu s'il appartient à la frontière de deux ou plusieurs classes. Ménard [MEN 98] définit la distance de l'individu X_k à la classe d'ambiguïté $A \in C$ par :

$$d_{AK} = \frac{\alpha_A (\sum_{C_i \in A} d_{ik})^2}{|A|^2 (\prod_{C_i \in C} d_{ik})^{\frac{1}{C}}} \tag{5.1}$$

où, le terme α_A est un nombre positif. d_{ik} est la distance classique utilisée dans l'algorithme FCM. La **Figure 38**, illustre le comportement de cette distance dans le cas de 3 classes. Les lignes en pointillés représentent le lieu d'ambiguïté totale vérifiant :

$$\text{Min } d_{Ak} \leq d_{ik} \quad \forall i \in \{1, \dots, c\} \quad (5.2)$$

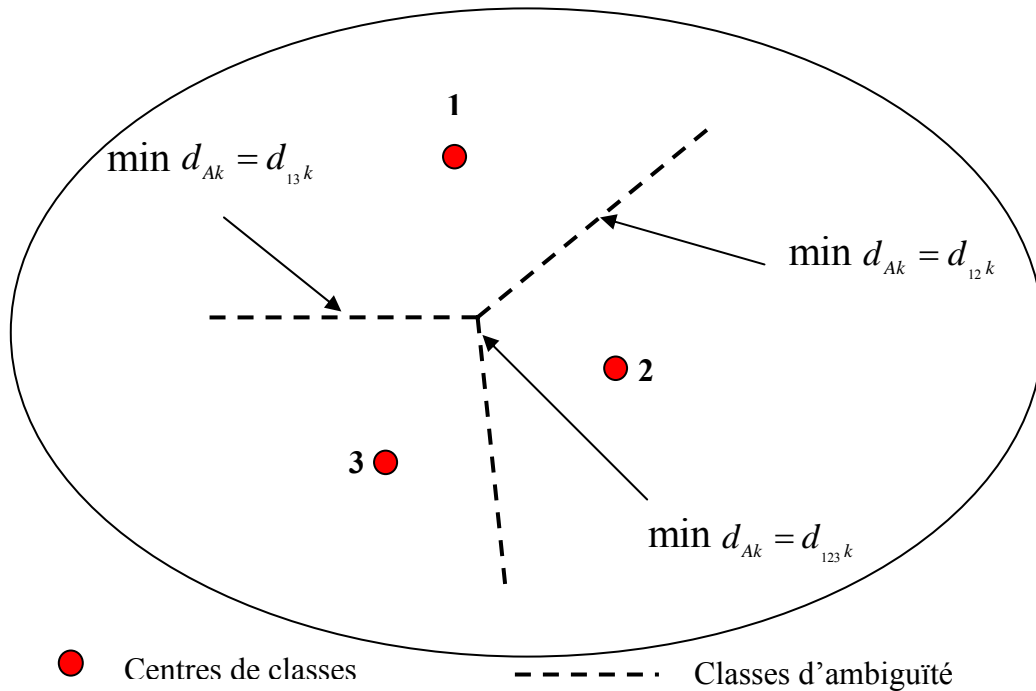


Figure 38 : les zones d'ambiguïté.

1.3. L'algorithme développé

L'algorithme développé baptisé FPCM, constitue une phase primaire dans le processus de coopération proposé. Autrement dit, on fait une première classification par l'algorithme FCM qui a pour objectif de calculer les centres des classes \mathbf{B} , puis une correction supplémentaire par l'algorithme PCM sera opérée.

2. Choix des paramètres de l'algorithme

Nous utilisons l'algorithme de classification possibiliste pour segmenter les tissus cérébraux dans les images IRM. Pour ce la, il nous faut définir les différents paramètres gouvernant la méthode, à savoir les valeurs de m et C , le choix des poids η_i , la métrique utilisée et enfin les vecteurs forme représentant les pixels des images.

2.1. Initialisation de l'algorithme

Le problème de la classification par FCM ou PCM s'exprime comme une minimisation d'une fonctionnelle, sous certaines contraintes. Les algorithmes sous-jacents n'assurent pas l'optimalité de la solution, puisqu'un minimum local peut être trouvé.

L'étape d'initialisation, conditionnant la recherche du minimum, est donc fondamentale. Plusieurs stratégies ont été proposées dans la littérature. La plus simple consiste à demander à

un expert de déterminer des régions d'intérêt représentatives des centres des classes. L'algorithme converge alors vers une solution acceptable, mais l'aspect non supervisé est perdu. Peña *et al.* [PEN 99] ont comparé quatre méthodes d'initialisation de la matrice de partition U (méthode totalement aléatoire, approches de Forgy, de MacQueen et de Kaufmann) et affirment que le meilleur schéma d'initialisation en termes de robustesse et de qualité de la partition est celui proposé par Kaufman et Rousseeuw [KAU 90]. Ces derniers proposent de sélectionner itérativement les centres de classe jusqu'à ce que C vecteurs soient choisis. Le premier vecteur retenu est le plus proche du centre de gravité de l'ensemble des vecteurs. Le centre suivant est sélectionné selon la règle heuristique du choix d'un élément promettant d'avoir autour de lui un maximum de vecteurs non encore sélectionnés.

L'utilisation d'une initialisation non supervisée présente cependant l'inconvénient de ne pas nécessairement converger vers une solution correcte [BAR99]. Ainsi, Velthuizen *et al.* [VEL 93] rapportent des résultats décevants de taux de reconnaissance de tissus cérébraux et pathologiques (tumeurs) par l'algorithme FCM, le tissu tumoral n'étant reconnu par l'algorithme que dans quatre cas sur dix. Le résultat obtenu dépend en grande partie de l'initialisation et de l'algorithme choisi. D'autre part, les algorithmes de minimisation tendent à privilégier les solutions dont les nuages de points ont des effectifs sensiblement égaux [BEN 96], [SUC 99].

Selon [KRI 96] l'algorithme PCM souffre du problème de rapprochement (coïncidence) des centres, cet inconvénient est due à une mauvaise initialisation de la partition.

Les résultats de PCM vont évidemment dépendre de l'étape d'initialisation. Tout algorithme (flou ou non) peut donc être utilisé, et FCM constitue une manière adéquate d'initialiser les données [BAR 99], puisqu'il donne accès à une première estimation des prototypes de classes B et de la matrice d'appartenance U .

L'algorithme de classification possibiliste est donc utilisé dans la suite en initialisant les données avec l'algorithme FCM et un critère d'arrêt n'autorisant que peu d'itérations (le PCM améliorera les résultats par la suite).

2.2. Détermination du nombre de classes

Nous nous plaçons ici dans une problématique de caractérisation de tissus cérébraux. Nous cherchons donc à segmenter la matière blanche, la matière grise, le liquide cérébro-spinal. C sera donc pris égal à trois. Suivant le cas étudié, rien n'empêche d'ajouter plusieurs classes pour détecter des éventuelles entités pathologiques (tumeurs,...etc).

2.3. Choix du paramètre m

Le paramètre m contrôle le degré de flou de la partition floue U . Si m est proche de 1, la partition résultante est quasiment non floue, chaque vecteur x_j est assigné à une classe i et une seule avec un degré d'appartenance $U_{ij}=1$. Inversement, alors que la croissance de m dans le FCM tend à augmenter le degré de partage des vecteurs aux classes (les degrés d'appartenance de x_j à chacune des C classes sont égaux à $1/C$ lorsque m tend vers l'infini), selon Bara dans [BAR 99] il n'existe pas de méthode pour optimiser de manière générale ce paramètre, chaque problème appelle un choix dépendant de la nature des données. Une valeur comprise dans l'intervalle $[1.5 ; 3]$ est généralement acceptée afin d'assurer la convergence de l'algorithme. Krishnapuram et Keller [KRI 96] suggèrent qu'un bon choix de m pour le PCM est $m = 1.5$

2.4. Choix de la distance

La métrique utilisée dans (2.14) conditionne la forme des nuages de points à séparer. D'une manière générale, la distance d^2 est définie par :

$$(\forall i \in \{1..C\})(\forall j \in \{1..N\}) d^2(x_j, b_i) = (x_j - b_i)^T \cdot A \cdot (x_j - b_i),$$

où A est une matrice définie positive. Lorsque A est la matrice identité, d^2 est la distance euclidienne et la structure des nuages de points est sphérique. D'autres choix sont possibles pour A , permettant de détecter des nuages de forme plus complexe. Nous donnons ici trois exemples rencontrés dans la littérature [BAR 99] :

- Gath et Geva [GAT 89] ont proposé une distance exponentielle fondée sur l'estimation d'un maximum de vraisemblance. Cette distance permet de générer et de détecter des nuages hyperellipsoïdaux variant par leur forme et leur densité. Si F_i est la matrice de covariance floue associée au nuage de points i , et si Q_i est la probabilité *a priori* de choisir la classe i , la distance est calculée par :

$$d^2(x_j, b_i) = \frac{[Det(F_i)]^{1/2}}{Q_i} \exp \left[\frac{1}{2} (x_j - b_i)^T F_i^{-1} (x_j - b_i) \right] \quad (5.6)$$

où

$$F_i = \frac{\sum_{j=1}^N u_{ij}^m (x_j - b_i) \cdot (x_j - b_i)^T}{\sum_{j=1}^N u_{ij}^m} \quad \text{et} \quad Q_i = \frac{1}{N} \sum_{j=1}^N u_{ij}^m \quad (5.7)$$

- Bezdek a introduit dans [BEZ 81] une distance permettant de détecter des nuages de points linéaires ou planaires. Les C prototypes \mathbf{b}_i ne sont plus de simples vecteurs, ce sont des variétés linéaires de dimension r , $0 \leq r \leq N-1$. La variété linéaire de dimension r passant par \mathbf{x}_j , engendrée par les vecteurs $\{\mathbf{e}_{j1}, \dots, \mathbf{e}_{jr}\}$ est donnée par :

$$L_{ri} = \{\mathbf{y} \in \mathbb{R}^n / \mathbf{y} = \mathbf{c}_j + \sum_{k=1}^r t_k \mathbf{e}_{jk}, t_k \in \mathbb{R}\} \quad (5.8)$$

Si $\{s_{ij}\}$ est une base orthonormale de cet espace, la distance est calculée par :

$$d^2(\mathbf{x}_j, \mathbf{b}_i) = d^2(\mathbf{x}_j, L_{ri}) = \left[\|\mathbf{x}_j - \mathbf{c}_i\|^2 - \sum_{k=1}^r ((\mathbf{x}_j - \mathbf{c}_i) \cdot s_{ik})^2 \right] \quad (5.9)$$

- Davé [DAV 90] a recherché des nuages de points hypersphériques en modélisant chaque centre de classe \mathbf{b}_i par une sphère de centre \mathbf{c}_i et de rayon r_i . La distance associée est alors :

$$d^2(\mathbf{x}_j, \mathbf{b}_i) = (\|\mathbf{x}_j - \mathbf{c}_i\| - r_i)^2 \quad (5.10)$$

Pour notre cas, nous avons donc utilisé l'algorithme PCM avec la distance la plus usuelle et la plus rapide à calculer, qui est la distance euclidienne [BAR 99].

2.5. Détermination des paramètres de pondération η_i

Les paramètres η_i déterminent la zone d'influence d'un vecteur \mathbf{x}_j pour la répartition des centres de classe. Ce vecteur aura une influence d'autant plus faible sur l'estimation de \mathbf{b}_i que la distance $d^2(\mathbf{x}_j, \mathbf{b}_i)$ sera grande devant η_i . En étudiant plus précisément les itérations du PCM, η_i peut être interprété comme le carré de la distance séparant \mathbf{b}_i de l'ensemble des vecteurs dont le degré d'appartenance à la classe i est égal à 0.5. Krishnapuram et Keller proposent dans [KRI 96] de choisir ce paramètre égal à la distance moyenne floue intra-classe, *i.e.* pour tout i dans $\{1..C\}$:

$$\eta_i = \frac{\sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i)}{\sum_{j=1}^N u_{ij}^m} \quad (5.11)$$

D'autres choix sont bien sûr possibles, mais n'apportent pas d'amélioration significative dans la classification finale [KRI 96]. L'algorithme PCM offre la possibilité de fixer, avant itérations, des valeurs pour ces paramètres, ou de faire recalculer les η_i au cours des itérations. Dans ce dernier cas, l'algorithme PCM peut évoluer vers des situations d'instabilité [KRI 96].

Les auteurs recommandent alors de fixer des valeurs avant itérations puis, si c'est nécessaire, de recalculer les η_i après convergence avec les nouvelles valeurs de U et B pour appliquer une seconde fois PCM.

2.6. Choix des vecteurs forme

Le choix des vecteurs forme est fondamental puisque leur pertinence va permettre de discriminer les pixels entre eux. Ce choix est défini suivant le type de modalité.

L'image anatomique que nous utilisons est une IRM. L'imagerie par résonance magnétique est une modalité d'imagerie multispectrale donnant accès à un grand nombre de paramètres et donc de vecteurs forme. La première caractéristique qui peut être exploitée est le signal lui-même, principalement par l'intermédiaire d'images pondérées en T_1 , T_2 et en densité de protons (cf. I.3.6). Le vecteur forme x_j d'un pixel j est alors formé des niveaux de gris de ce pixel dans toutes les images. Cette information est très largement utilisée en segmentation d'images, en particulier dans un cadre flou [SUC 99] ou non flou [MOH 99], mais elle est dans ce cas très sensible aux variations du signal dues à l'instrumentation (hétérogénéité de champ, cf. I.3.7.3).

Kiviniitty [KIV 84] affirme que les paramètres T_1 et T_2 suffisent à discriminer correctement les tissus sains dans des images IRM. Just et al. [JUS 88] partagent cette opinion, mais notent que certaines entités pathologiques (tumeurs, œdèmes) sont caractérisées par un grand nombre de valeurs dans les images pondérées en T_1 , T_2 et en densité de protons, et que cette variété peut affecter l'analyse de ces entités.

3. Algorithmes utilisés

Algorithme FCM

Etape 1 : fixer les paramètres.

Les entrées : $X = (x_j, j=1..N)$ l'ensemble des vecteurs forme, C : nombre de classes
 \mathcal{E} : Seuil représentant l'erreur de convergence (par exemple $\mathcal{E} = 0.001$)
 m : Degré de flou, $m \in [1.5, 3]$.

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

Etape 3 : mettre à jour la matrice prototype B par la relation $b_i \leftarrow \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}$

$$J^{Ancien} \leftarrow \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i)$$

Etape 4 : mettre à jour la matrice degrés d'appartenance par la relation

$$u_{ij} \leftarrow \left[\sum_{k=1}^C \left(\frac{d^2(\mathbf{x}_j, \mathbf{b}_i)}{d^2(\mathbf{x}_j, \mathbf{b}_k)} \right)^{2/(m-1)} \right]^{-1}$$

$$J^{Nouveau} \leftarrow \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i)$$

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

$$\| J^{Ancien} - J^{Nouveau} \| \leq \varepsilon$$

Les sorties : la matrice d'appartenance U et les centres des classes B.

Algorithme PCM

Etape 1 : fixer les paramètres.

Les entrées : [$X=(x_j, j=1..N)$] l'ensemble des vecteurs forme, C : nombre de classes

ε : Seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0.001$)

m : Degré de flou, $m = 1.5$. η_i : Degré de pondération

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

Etape 3 : mettre à jour la matrice prototype B par la relation

$$b_i \leftarrow \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}$$

$$J^{Ancien} \leftarrow \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i) + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m$$

Etape 4 : mettre à jour la matrice degrés d'appartenance par la relation

$$u_{ij} \leftarrow \frac{1}{1 + \left(\frac{d^2(\mathbf{x}_j, \mathbf{b}_i)}{\eta_i} \right)^{\frac{1}{m-1}}}$$

$$J^{Nouveau} \leftarrow \sum_{i=1}^C \sum_{j=1}^N u_{ij}^m d^2(\mathbf{x}_j, \mathbf{b}_i) + \sum_{i=1}^C \eta_i \sum_{j=1}^N (1 - u_{ij})^m$$

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

$$\| J^{Ancien} - J^{Nouveau} \| \leq \varepsilon$$

Les sorties : la matrice d'appartenance U et les centres des classes B.

Algorithme général de l'approche

Etape 1 : fixer les paramètres.

Les entrées : [$X=(x_j, j=1..N)$ l'ensemble des vecteurs forme, $2^c - 1$: nombre de classes

\mathcal{E} : Seuil représentant l'erreur de convergence (par exemple $\mathcal{E} = 0.001$)

m : Degré de flou, $m \in [1.5, 3]$. η_i : Degré de pondération

Etape 2 : lancer l'algorithme FCM

Etape 3 : corriger les résultats avec PCM.

Les sorties : la matrice d'appartenance U.

L'approche proposée est coopérative hybride (coopération par fusion + coopération par initialisation), cette coopération nécessite comme on la vu dans les chapitres précédents une architecture multi agents pour son implémentation.

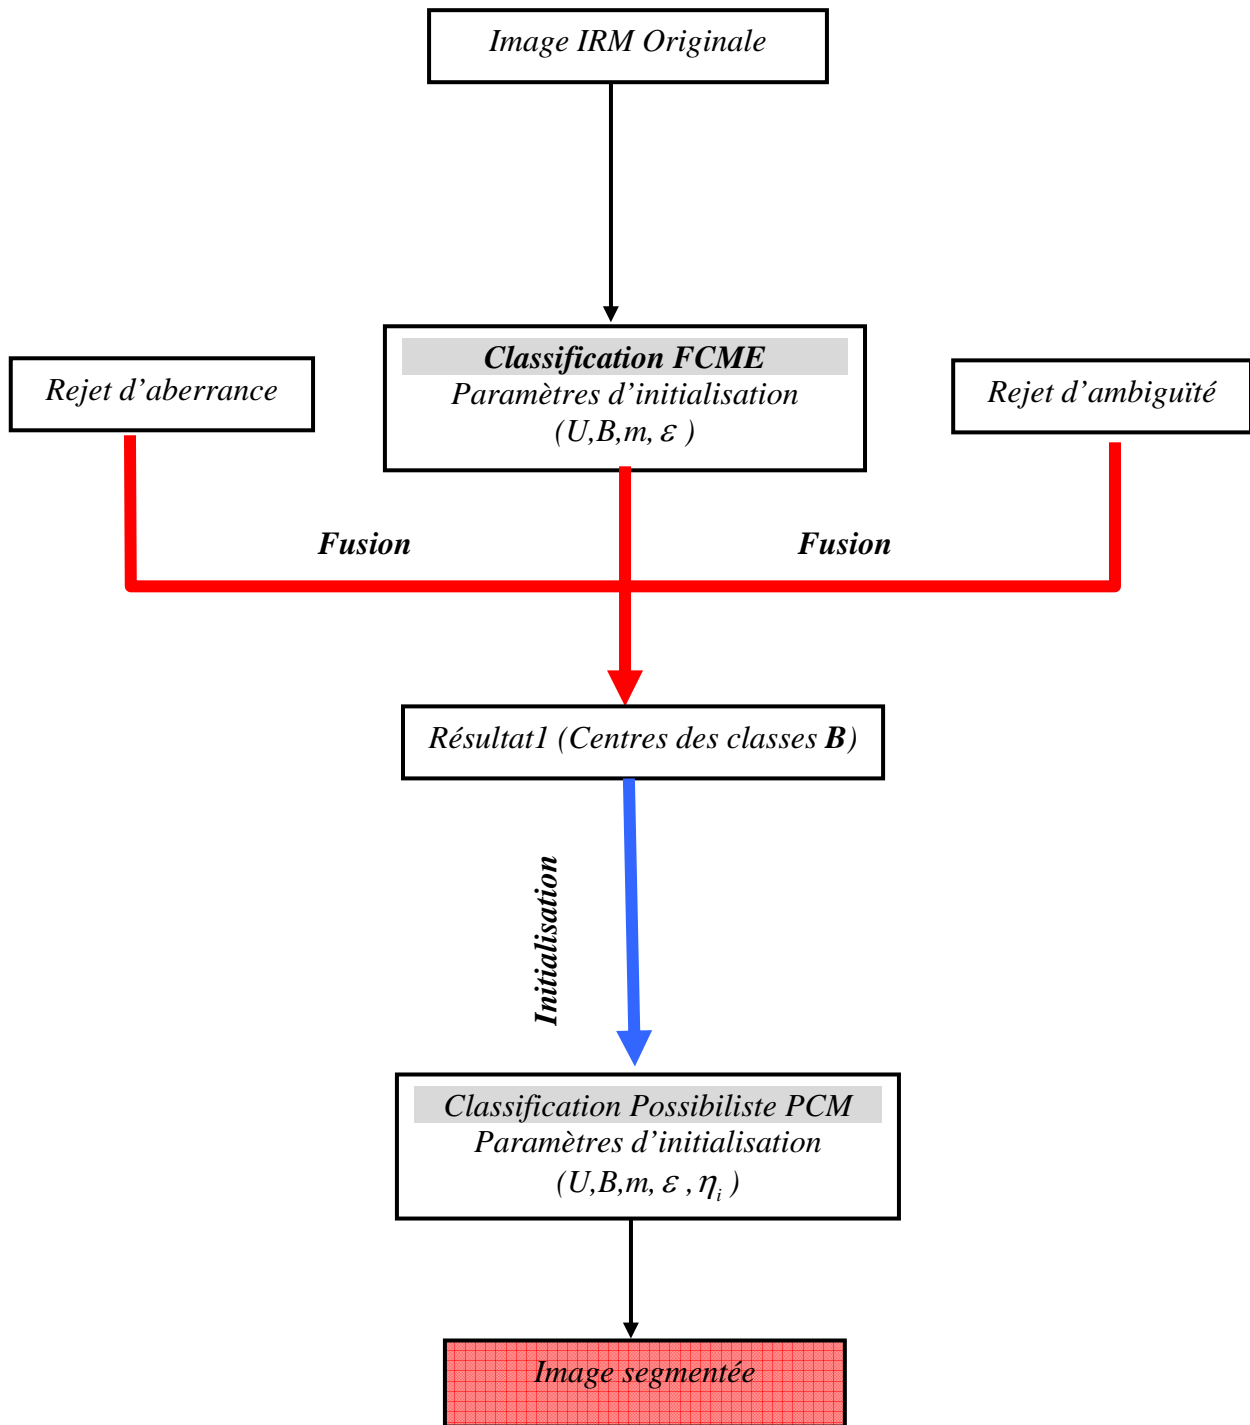


Figure 39 : étapes de la coopération hybride (fusion + initialisation) de l'approche proposée.

4. Pourquoi une architecture multi-agent ?

Dans le contexte de l'approche proposée, le parallélisme permet d'envisager de réaliser la fusion simultanée des résultats de deux agents, l'un est chargé à rejeter les individus ambigus (rejet d'ambiguïté) et l'autre chargé de rejeter les individus aberrants (rejet d'aberrance).

La **Figure 40** illustre l'interaction entre agents dans l'approche proposée. Différentes classes d'agents ont été définies pour répondre à des besoins spécifiques, tels que la modularité, la robustesse...etc.

5. La plate-forme multi agents

Pour toute application multi agents il faut choisir la plate-forme adéquate, pour notre application la plate forme choisie est MAGIQUE.

La plateforme MAGIQUE signifie "*multi agent hiérarchique*". Elle est à la base un modèle d'organisation d'agents qui propose une organisation hiérarchique. Cette structure permet de proposer un mécanisme de délégation de compétences entre agents, facilitant ainsi le développement. Elle a été développée par l'équipe SMAC de l'université LIFL de Lille³.

5.1. Caractéristiques de MAGIQUE

- Dans la plateforme *Magique*, un agent est une entité possédant un certain nombre de compétences. Ces compétences permettent à un agent de tenir un *rôle* dans une application multi-agents. Les compétences d'un agent peuvent évoluer dynamiquement (par échanges entre agents) au cours de l'existence de celui-ci, ce qui implique que les *rôles* qu'il peut jouer (et donc son statut) peuvent également évoluer au sein du SMA. Un agent est construit dynamiquement à partir d'un agent élémentaire "vide", par enrichissement/acquisition de ses compétences.

- Dans *Magique* les agents sont définis au sein d'une plate-forme d'accueil, une application *Magique* peut fonctionner selon deux modes d'exécution différents :

Centralisé : Dans ce cas, tous les agents lancés tournent dans une machine.

Distribué : Dans ce cas, les agents tournent sur des machines différentes. Il y a alors une plateforme sur chaque machine et les agents distants communiquent entre eux via leurs plateformes.

³ www.lifl.fr/

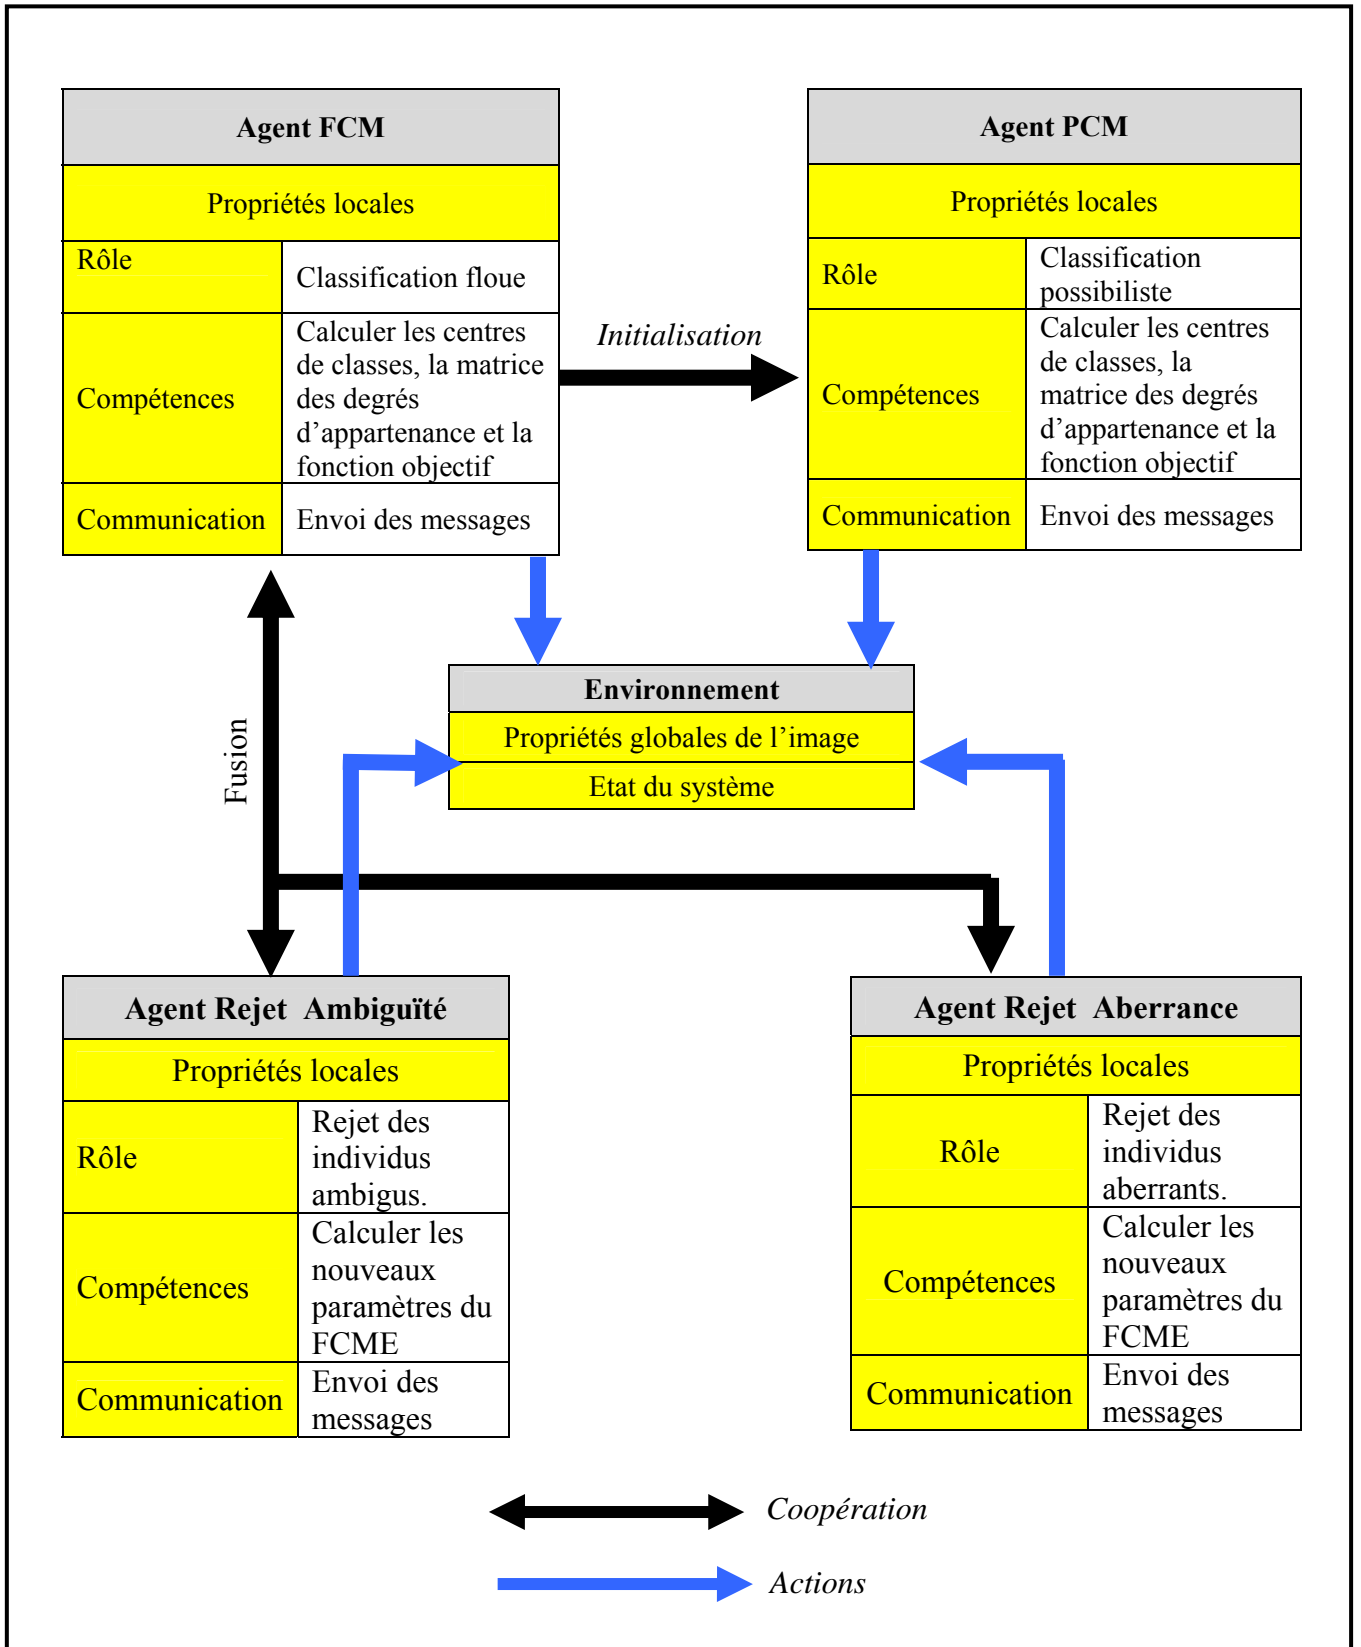


Figure 40: Le système multi-agents proposé.

• Agent et compétences

1. *Agent atomique* : *Magique* utilise la notion d'*agent atomique*, un *agent atomique* est une entité douée de deux compétences : une pour interagir et l'autre pour apprendre de nouvelles compétences. Un agent est un agent atomique qui a appris des compétences à travers des communications.




Figure 41 : Structure d'agent atomique

2. *Compétence* : Dans *Magique* une compétence est une classe qui implémente directement ou indirectement l'interface `fr.lifl.magique.skill.Skill` (le plus souvent les compétences hériteront en fait de la classe `MagiqueDefaultSkill` qui permet d'encapsuler et d'offrir dans les compétences des fonctionnalités pratiques souvent utiles). Les méthodes publiques de ces compétences seront les fonctionnalités qui pourront être utilisées et donc invoquées par l'agent.

3. *Education d'un agent* : Nous pouvons donc considérer que tous les agents sont identiques (du point de vue des compétences) à leur naissance (création) : une coquille avec uniquement les deux compétences mentionnées précédemment.

Il en résulte que les différences entre les agents proviennent de leur éducation, c-à-d des compétences qu'ils auront acquises au cours de leurs "existence". Ces compétences peuvent ou bien avoir été données lors de leur création par le programmeur, ou avoir été dynamiquement apprises suite à des interactions avec d'autres agents.

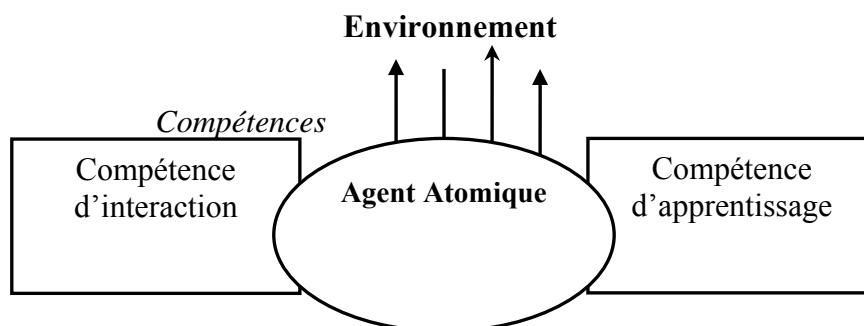


Figure 42 : Education d'un agent.

Attribuer des compétences à un agent c'est lui offrir la possibilité de tenir un rôle particulier dans un SMA auquel il appartient. Avec *Magique* on peut soit ajouter à un agent des compétences avec l'instruction `addSkill` ou les supprimées avec `removeSkill`.

Le paradigme de construction dynamique d'agents par enrichissement de compétences, procure de nombreux avantages au niveau de la conception :

➤ *le développement est facilité* : Construire un agent c'est lui enseigner des compétences, la programmation d'un agent est donc "réduite" à celle de compétences, et une fois qu'une compétence a été développée elle peut être réutilisée dans différents contextes. Les compétences peuvent être vues comme des *composants logiciels*, avec tous les avantages liés à cette notion : modularité, réutilisabilité, etc.

➤ *robustesse* : Si pour quelque raison un agent doit disparaître du SMA et qu'il est le détenteur d'une compétence critique, il peut l'enseigner à un autre agent du SMA et ainsi garantir la pérennité et la cohérence de l'ensemble.

➤ *autonomie et évolutivité* : Au cours de sa "vie", une compétence donnée d'un agent peut évoluer et être améliorée, et de nouvelles compétences peuvent être ajoutées. Ainsi l'agent accroît ses capacités et son autonomie.

• **La Hiérarchie :**

Une hiérarchie est un arbre dont la racine est un agent et dont les fils sont, quand il y en a, également des hiérarchies. Les agents feuille sont appelés *spécialistes* et les autres *superviseurs*, ceux-ci doivent être capables (avoir la compétence) de gérer leur *équipe* d'agents (la sous hiérarchie) dont ils sont la racine.

Une hiérarchie représente la structure initiale des SMA et induit le support par défaut des communications entre les agents. Un lien hiérarchique représente donc l'existence d'un lien de communication entre ces agents, et lorsque deux agents d'une même structure hiérarchique communiquent, le chemin emprunté par les messages qu'ils s'échangent suit les relations d'accointances, par défaut, à la hiérarchie. Cette communication est alors essentiellement verticale. *Magique* offre la possibilité de créer des liens directs (en dehors de la hiérarchie) entre deux agents. Nous les appellerons *liens d'accointances*.

5.2. Différentes méthodes de communication entre agents

Un système multi agent commence à deux agents, et dès qu'il y en a deux, il faut leur permettre de communiquer. Il est donc nécessaire de les mettre en relation (les connecter) et ensuite de leur permettre de s'envoyer des messages (nous diront aussi requêtes pour éviter une connotation trop objet). *Magique* dispose d'un certain nombre de méthodes :

- La méthode `perform` est utilisée pour les méthodes qui ne renvoient pas de résultats avec la syntaxe suivante :

```
Perform ("Nom_Methode", Tableau d'arguments) ;
```

- La méthode `askNow` () appel de méthode synchrone avec résultat. Quand cette méthode est appelée, l'exécution de l'agent se fige jusqu'à obtention du résultat. elle est utilisée avec la syntaxe suivante :

```
askNow ("Nom_Methode", Tableau d'arguments) ;
```

- La méthode `ask` () appel de méthode asynchrone avec résultat. Après l'appel de cette méthode, l'agent continue son exécution. Si quelqu'un répond à cette requête, la réponse est rangée dans un tableau de réponses propre à chaque agent. C'est l'agent lui-même qui doit explicitement aller chercher la réponse. Elle est utilisée avec la syntaxe suivante :

```
ask ("Nom_Methode", Tableau d'arguments) ;
```

5.3. Le Routage des messages

Lorsqu'un agent *Magique* appelle une méthode par `perform`, `askNow` ou `ask`, le routage se fait de la manière suivante :

- 1) L'agent regarde s'il connaît cette méthode. Si oui il l'exécute.
- 2) Si non, il regarde si il a une équipe à sa charge (s'il est superviseur) dont l'un des agents possède la compétence recherchée, cet agent peut être présent à une profondeur quelconque de la hiérarchie qu'il contrôle. Si c'est le cas il transmet la requête à l'un des agents situé immédiatement en dessous de lui et qui contrôle une sous hiérarchie dans laquelle se trouve (au moins) un agent compétent (éventuellement cet agent lui-même). Cet agent répète alors le même processus.
- 3) S'il n'y en a aucun, il transmet la requête à son propre superviseur qui effectue le même raisonnement ... et ainsi de suite.
- 4) Enfin le dernier cas, s'il est lui même la racine de la hiérarchie (*big boss*) et qu'il n'y a donc pas d'agent compétent dans cette hiérarchie, il met la requête en attente jusqu' à ce qu'un agent compétent rejoigne la structure ou qu'un agent déjà présent apprenne la compétence requise.

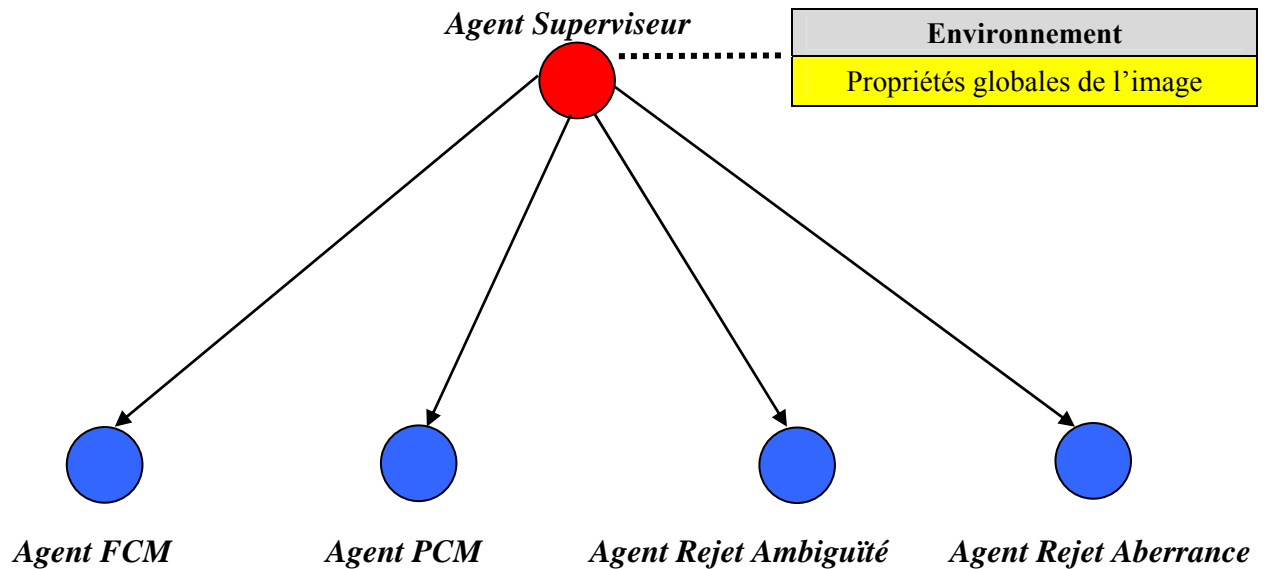


Figure 43 : La hiérarchie des agents.

5.4. Les avantages de Magique

- *Magique* permet de développer facilement des agents selon les cas, les agents peuvent tourner sur une même machine ou sur des machines physiquement distribuées sur un réseau.
- *Magique* permet de masquer les aspects techniques de communication entre agents, le multi threading et la gestion des flux. Elle banalise la communication entre agents..
- Avec *Magique* inutile de savoir qui possède une compétence, il suffit de savoir qu'elle existe. Cela permet une grande réutilisabilité des agents indépendamment du contexte.
- *Magique* est facile à apprendre.

Conclusion

Dans ce chapitre nous avons décrit l'approche proposée, avec la présentation de l'architecture générale des agents et les paramètres de chaque algorithme développé.

Pour tirer parti des complémentarités qui existent entre l'algorithme FCM (dont la contrainte d'appartenance d'un individu à une classe est gérée d'une relative), et l'algorithme PCM (qui relâche cette contrainte), nous avons introduit le caractère coopératif où la coopération par fusion est utilisée en premier temps pour fusionner les informations issues de l'algorithme FCM, et dans un second temps la coopération séquentielle est utilisée pour injecter ces informations à l'algorithme PCM.

Pour coordonner et contrôler le processus de segmentation, le paradigme multi-agents est introduit, donc il fait intervenir, à différents niveaux, cinq agents chacun a des compétences spéciales, depuis l'agent superviseur qui gère toutes les interactions entre les agents à l'agent

rejet d'aberrance qui rejette les individus les plus éloignés par rapport aux centres de classes. Toutes les interactions et communications se déroulent dans une plateforme *Magique* qui permet de masquer les aspects techniques de communication entre agents, et facilite la création et la destruction des agents.

Dans le chapitre suivant nous allons présenter les premiers résultats, afin d'évaluer l'efficacité du système développé.

CHAPITRE VI : Résultats et évaluations.

Introduction

Dans la segmentation d'images, la validation des résultats obtenus est un problème délicat où plusieurs approches peuvent être envisagées dans le but de fournir une évaluation quantitative et qualitative des résultats. Nous distinguerons principalement les approches exploitant les résultats de segmentation réalisées manuellement par des experts sur des images réelles et les approches exploitant des images de synthèse pour lesquelles les références sont parfaitement connues.

Dans ce chapitre nous présentons les résultats obtenus par le système développé (FPCM), sur des images réelles et simulées (mises à disposition sur le site internet brainweb⁴).

1. Les images réelles et simulées utilisées pour l'évaluation

1.1. Les images réelles

Les images réelles sur lesquelles nous avons travaillé ont été acquises dans le cadre de la collaboration entre le laboratoire LSI (Laboratoire Systèmes Intelligents : équipe image et signaux) de l'université Ferhat Abbas de Sétif et le Centre de Recherche en Sciences et Technologies de l'Information et de la Communication (CReSTIC) équipe LAM (Traitement d'images) IUT de Troyes

Il s'agit d'images pondérées en T_1, T_2 et en densité de proton pour des patients de différents âges (taille pixel =1mm, taille de matrice 512X 512). Les images sont en format DICOM (*Digital Imaging and Communications in Medicine*) qui sera détaillé dans l'annexe.

1.2. Les fantômes (images de synthèse)

Afin d'évaluer quantitativement le système développé, nous avons utilisé des images de synthèse générées à l'aide du simulateur proposé par BrainWeb. Il s'agit d'images de synthèse dont il est possible de contrôler les paramètres d'épaisseur de coupe, bruit et d'hétérogénéité, etc.

Les images sont créées à partir de 27 acquisitions réalisées sur un même individu et caractérisées par un rapport signal/bruit élevé. Le volume initial utilisé pour la construction d'un «fantôme» de cerveau est constitué par la moyenne de ces acquisitions. Les principales étapes mises en œuvre afin de transformer le volume initial en un fantôme permettant de générer des simulations sont les suivantes :

⁴ www.bic.mni.mcgill.ca/brainweb

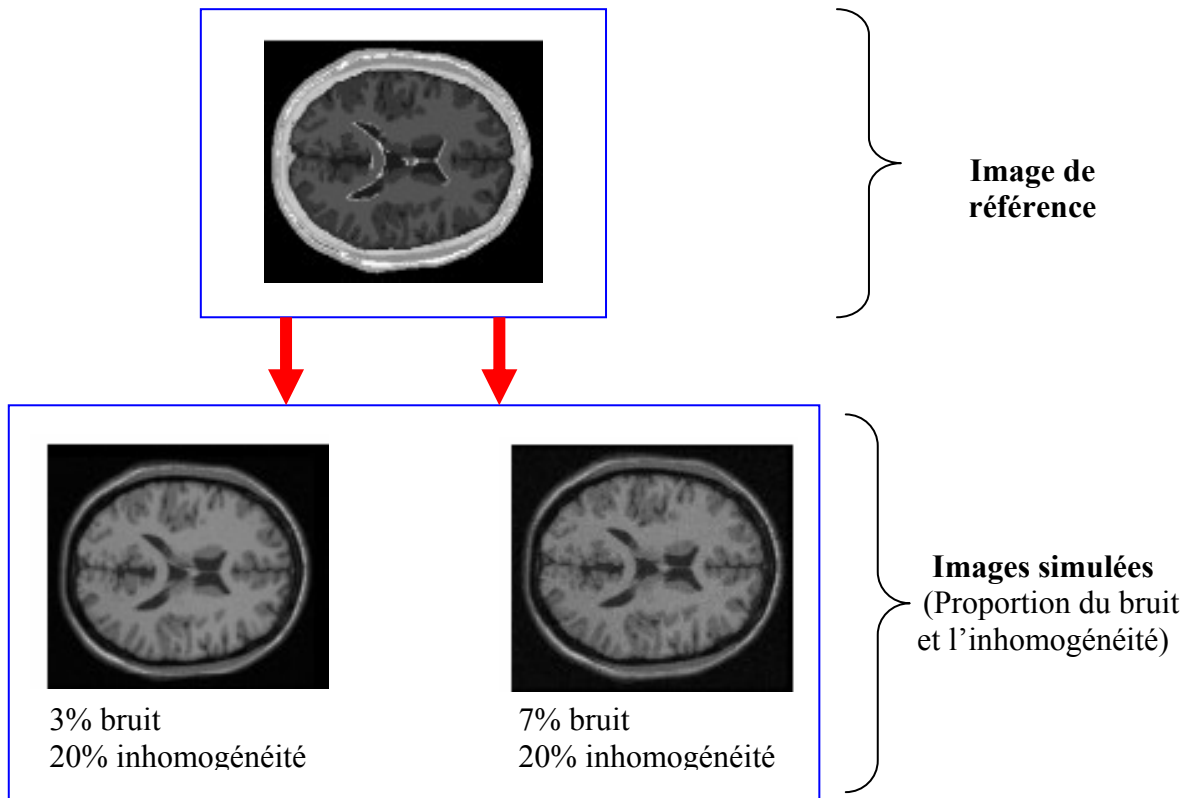


Figure 44 : *Processus de construction des images simulées.*

- *la correction des non-uniformités* : Avant tout traitement du volume initial, un algorithme de correction des non-uniformités des niveaux de gris a été appliqué afin de réduire au maximum les risques d'erreurs de classification.
- *la classification* : La classification a été réalisée à partir d'un ensemble d'apprentissage décrivant des exemples de pixels appartenant aux différents tissus recherchés et marqués par un expert. Plusieurs algorithmes de classification ont été testés et le principe des plus proches moyennes a été retenu comme fournissant le meilleur résultat [GER 99]. Afin de construire un fantôme réaliste, les effets de volume partiel sont pris en compte. Ainsi pour chaque pixel du volume, un vecteur décrit la proportion de chacun des tissus qui le constituent. Le résultat de la classification est finalement constitué par 9 volumes décrivant chacun l'un des tissus recherchés (matière blanche et grise, liquide céphalo-rachidien, graisse, muscles, crâne, air,...etc). Au sein de chaque volume, l'intensité d'un pixel représente sa fraction pour le tissu correspondant.
- *les corrections manuelles* : Un ensemble de corrections manuelles ou semi-automatiques a été réalisé afin d'améliorer le résultat de la segmentation. Ainsi, le

fantôme final est composé de 9 volumes de tissus corrigés et la carte de référence qui lui est associée correspond en chaque pixel au tissu le plus représenté. Ce fantôme permet de décrire une géométrie réaliste de cerveau humain.

- *les simulations* : Les niveaux de gris simulés pour chaque pixel du volume ont été obtenus par résolution des équations de Bloch [GER 99].

2. Evaluation et étude comparative

Il n'existe pas de "bonne" segmentation. Seule l'appréciation de l'utilisateur (qualité visuelle) et le but recherché permettent de définir une bonne segmentation pour un type de données. C'est pour cette raison qu'il est nécessaire de mesurer et quantifier les performances de la segmentation.

2.1. Le protocole d'évaluation

L'utilisation d'images de synthèse permet de comparer quantitativement la segmentation obtenue par rapport à un référentiel (Talairach⁵) (Figure 45). La robustesse des systèmes de segmentation peut ainsi être étudiée et comparée pour différents niveaux de bruit et d'hétérogénéité d'intensité des images simulées. Il est également possible pour un même système de segmentation de tester quantitativement l'influence du choix de certains paramètres sur les résultats de la segmentation.

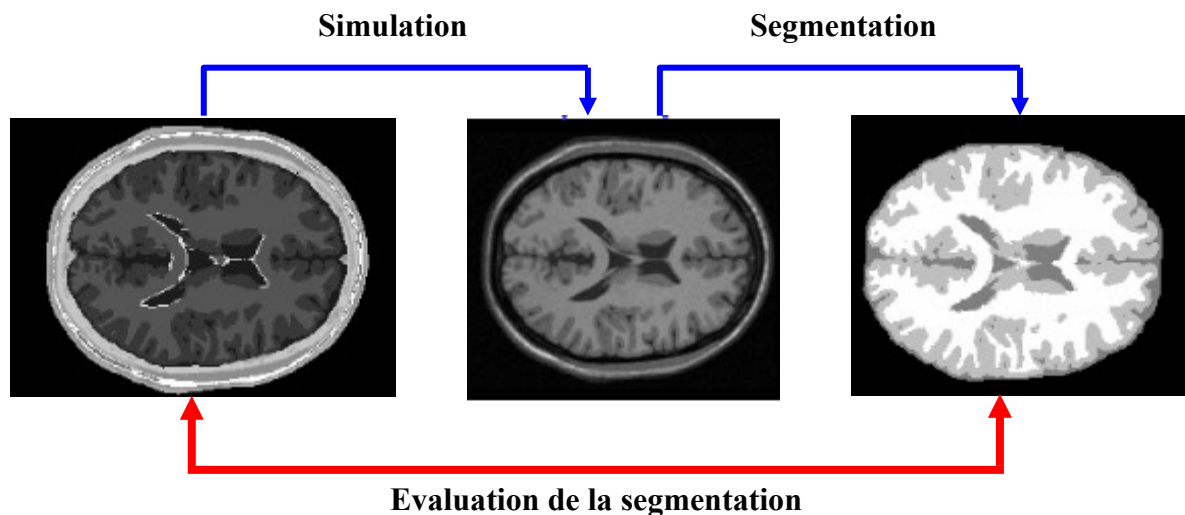


Figure 45 : Processus d'évaluation sur des images fantômes

⁵ Le référentiel de **Talairach** est un système de coordonnées permettant de repérer la position de n'importe quel point dans le cerveau d'un individu quelconque en référence à un atlas publié par les médecins Jean Talairach

2.2. Taux de recouvrement

On définit ce taux de recouvrement $R(\%)$ entre l'ensemble A et B par :

$$R(\%) = \frac{A \text{ et } B}{A \text{ ou } B} \quad (6.1)$$

où "**et**" signifie l'opération et logique et "**ou**" l'opération ou logique.




Figure 46 : Deux régions A et B

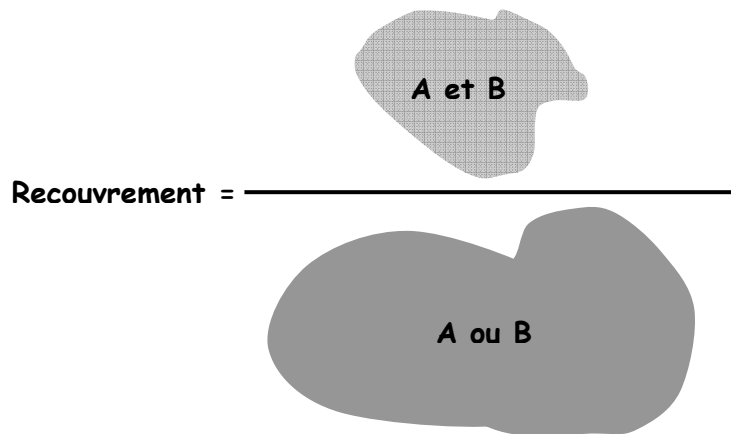


Figure 47 : Recouvrement entre les deux régions A et B

Une approche classique présentée par Vinet [VIN 91] consiste à calculer le pourcentage de pixels mal appariés entre deux segmentations. Or l'inconvénient de cette mesure est qu'elle ne fait pas intervenir d'information spatiale sur la localisation de ces pixels. L'approche développée par Kara Falah et Bolon [KAR 93] est une extension au cas de deux segmentations de la mesure de distance entre deux régions présentée par Baddeley [BAD 92]. Soit X l'ensemble des pixels de l'image, N le nombre total de pixels, A et B deux régions de X . La distance de Hausdorff entre A et B est définie par Haacke et Tkach [HAA 90] :

$$H(A, B) = \max \left\{ \sup \{ d(x, B) / x \in A \} ; \sup \{ d(x, A) / x \in B \} \right\} \quad (6.2)$$

avec $d(x, A) = \inf \{ \rho((x, a) / a \in A) \}$ où $\rho(x, a)$ est une distance définie entre deux points de X . $H(A, B)$ est la distance maximale très intéressante théoriquement car elle a une relation directe avec les opérations de base de la morphologie mathématique. En revanche, H est

sensible au bruit à cause de l'utilisation de sup dans sa définition. Pour pallier cet inconvénient, Baddeley [BAD 92] a remplacé le sup par le moment d'ordre ρ . En remarquant que la distance de Hausdorff entre deux régions peut s'écrire sous la forme :

$$H(A, B) = \sup \{ |d(x, A) - d(x, B)| \mid x \in X \} \quad (6.3)$$

où A , et B sont deux régions de X , Baddeley remplace cette mesure par :

$$V^p(A, B) = \left[\frac{1}{N} \sum_{x \in X} |d(x, A) - d(x, B)|^p \right]^{\frac{1}{p}} \text{ avec } p = 1, 2, 3, \dots \quad (6.4)$$

lorsque p tend vers l'infini, on retrouve la mesure de Hausdorff. L'avantage de la mesure de Baddeley est qu'elle est moins sensible au bruit, surtout pour les valeurs faibles de p .

Baddeley propose une deuxième version de cette mesure, dans laquelle la distance ρ entre deux pixels est pondérée par l'application d'une concave. La mesure entre deux pixels devient :

$$\tau(x, y) = w(\rho(x, y)) \quad (6.5)$$

où $w(t)$ est une fonction continue, concave et bornée sur $[0, \infty[$.

La nouvelle distance de Bradley s'écrit alors :

$$V^p(A, B) = \left[\frac{1}{N} \sum_{x \in X} |w(d(x, A)) - w(d(x, B))|^p \right]^{\frac{1}{p}} \text{ avec } p = 1, 2, 3, \dots \quad (6.6)$$

Cette transformation donne une contribution négligeable des pixels assez éloignés A et B . La distance entre A et B ne dépend alors que de leur voisinage immédiat. On peut citer comme exemples pour la fonction $w(t)$, $w_1(t) = \frac{t}{t+1}$ et $w_2(t) = a \tan(t)$. Finalement, si deux segmentations sont identiques, la distance est nulle; dans le cas contraire, elle tend vers 1.

Il existe autres coefficients décrits dans [SHU 99], définis pour valider des systèmes d'imagerie. Les trois coefficients proposés sont le Building Detection Percentage (BDP), le Branching Factor (BF) et le Quality Percentage (taux de recouvrement) (QP) définis respectivement par les équations (6.7), (6.8) et (6.9) :

$$BDP = \frac{VP}{VP + FN} \quad (6.7)$$

$$BF = \frac{FP}{VP} \quad (6.8)$$

$$QP = \frac{VP}{VP + FP + FN} \quad (6.9)$$

où le nombre de Vrais Positifs (**VP**), c'est-à-dire de pixels détectés à raison, le nombre de Faux Positifs (**FP**), c'est-à-dire de pixels détectés à tort, le nombre de Vrais Négatifs (**VN**), c'est-à-dire de pixels non détectés à raison et le nombre de Faux Négatifs (**FN**), c'est-à-dire de pixels non détectés à tort, sont généralement calculés pour chaque classe de tissus (**Figure 48**).




Figure 48 : Définition des valeurs de Vrais Positifs (**VP**), Vrais Négatifs (**VN**), Faux Positifs (**FP**) et Faux Négatifs (**FN**) par comparaison de l'image de référence (ensemble A) et de l'image segmentée (ensemble B).

- Le Building Detection Percentage est en fait équivalent à la mesure de sensibilité et quantifie la fraction de pixels qui ont été correctement classifiés par le système. Dans le cas idéal, ce coefficient vaut 1.
- Le Branching Factor quantifie la sur détection de pixels n'appartenant pas au tissu recherché dans la carte de référence. Dans le cas idéal ce coefficient vaut 0.
- Le Quality Percentage (le taux de recouvrement) représente la qualité globale absolue du système de segmentation. Dans le cas idéal ce coefficient vaut 1.

3. Résultats

3.1. Images de synthèse

- **Image (e)** : la classe LCS est très semblable à celle issue de l'image originale, la classe LCS n'apporte en effet aucune information supplémentaire quant à la localisation du liquide. la classe MG souffre de l'absence du putamen, ce qui rend cette image imprécise.
- **Image (h)** : la distinction entre les différentes classes segmentées ne s'exprime pas complètement (problèmes d'initialisations des centres de classes).
- **Image (k)** : l'interprétation des classes est complètement améliorée par rapport aux (FCM, PCM), on remarque la distinction entre les 3 classes du cerveau et la visibilité de la classe LCS, (invisible dans les deux approches précédentes).
- **Image (f)** : la classe LCS issue de DP n'apporte en effet aucune information supplémentaire quant à la localisation du liquide. La classe MB est fortement améliorée par rapport à l'image originale.
- **Image (i)** : le PCM n'apporte presque pas de grande chose par rapport au FCM en DP.
- **Image (l)** : le FPCM apporte une grande performance à la segmentation pour la classe MB mais pour la classe LCS, il reste toujours pas complètement visible c-à-d la classe LCS n'apporte en effet aucune information supplémentaire.

Remarque

L'algorithme utilisé pour valider les résultats est le FPCM. Nous avons trouvé des difficultés pour introduire les notions de rejets (changement des fonctions objectif) et pour implémenter les agents proposés (problèmes de plateforme). C'est pour cette raison qu'on a utilisé l'algorithme coopératif flou suivi du possibiliste seulement sans utiliser les SMA.

Images originales (coupe axiale)



(a) Image en T1



(b) Image en T2




(c) Image en DP

Segmentation Floue FCM



(d)



(e)




(f)

Segmentation Possibiliste PCM



(g)



(h)



(i)

Segmentation Approche développée FPCM



(j)



(k)



(l)

Figure 49 : Comparaison des images segmentées par différentes approches de classification (images saines).

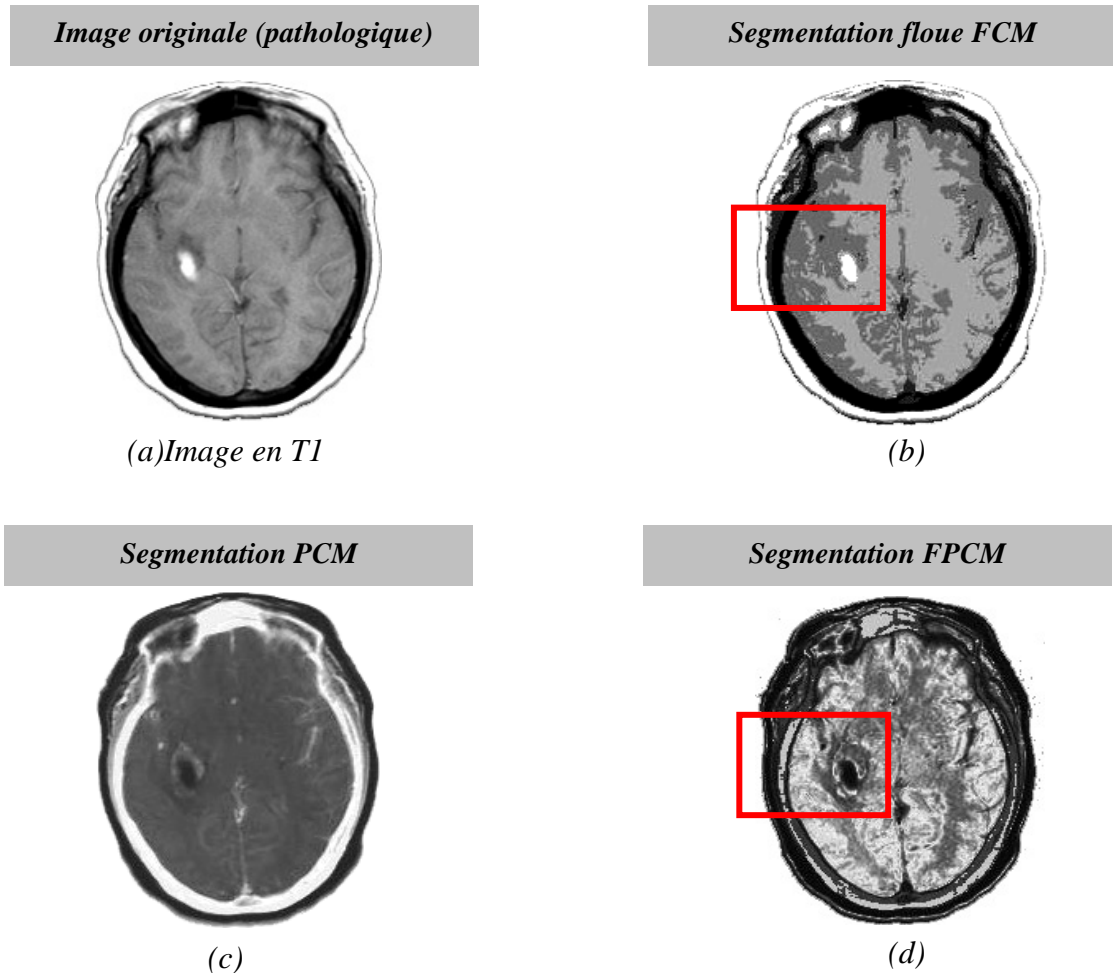


Figure 50 : Comparaison des images segmentées par différentes approches de classification (images pathologiques)

- **Image (b) :** la classe LCS n'est pas conforme à celle de l'image originale. Le manque d'informations sur les petits sillons (image (a)) et la mauvaise discrimination LCS/MG font que la classe LCS segmentée représente mal la distribution du liquide. Les distributions de MB et MG quant à elles se rapprochent de celles fournies par l'image originale.
- **Image (c) :** PCM est mal adapté dans cette segmentation
- **Image (d) :** le FPCM apporte une grande performance à la segmentation pour les trois classes et surtout pour la quatrième classe qui est la pathologie qui spécifie bien la taille et les détails sur cette dernière

Remarque :

Pour les images (j),(k) issues de la segmentation par le système développé on remarque la présence de nouvelle classe (entourer par le rectangle), cette classe n'a pas été détectée dans l'approche floue et possibiliste.

Remarque :

L'algorithme que nous avons développé tourne sur machine Pentium 4, une mémoire de 256 Mo, et avec les paramètres suivants ($\epsilon = 0.05$, nombre de classe = 4). Nous avons choisi le $\epsilon = 0.05$ pour accélérer le calcul.

3.2. Images réelles

La segmentation du cerveau a été appliquée avec succès sur une soixantaine d'images réelles (format DICOM). Les résultats sont illustrés sur les **Figures 51 à 56**.

Nature	Images IRM cérébrales
Pondérations	T1, T2, densité de proton
Coupes	Axiales, sagittales, coronales
Taille	512*512
Patients	Enfants, Hommes
Formats	DICOM
Dates d'acquisition	-----

Tableau 4 : *Propriétés des images utilisées.*

On a préféré présenter les images segmentées sur des coupes différentes afin de prouver l'efficacité de l'approche développée.

Pendant tout le processus de segmentation des images réelles, nous avons remarqué que le temps nécessaire pour segmenter une image (nombre d'itérations de chaque algorithme >50, taille 512*512) est très élevé (55 min pour 200 itérations). C'est pour cette raison qu'on a choisi $\epsilon = 0,05$

Le **Tableau 8** présente les temps d'exécutions enregistrés pour chaque segmentation d'images réelles.




Figure 51 : *Images originales : coupes axiales (différentes pondérations Dp, T1, T2)*




Figure 52 : Segmentation par FPCM : coupes axiales (différentes pondérations T1, T2, Dp)

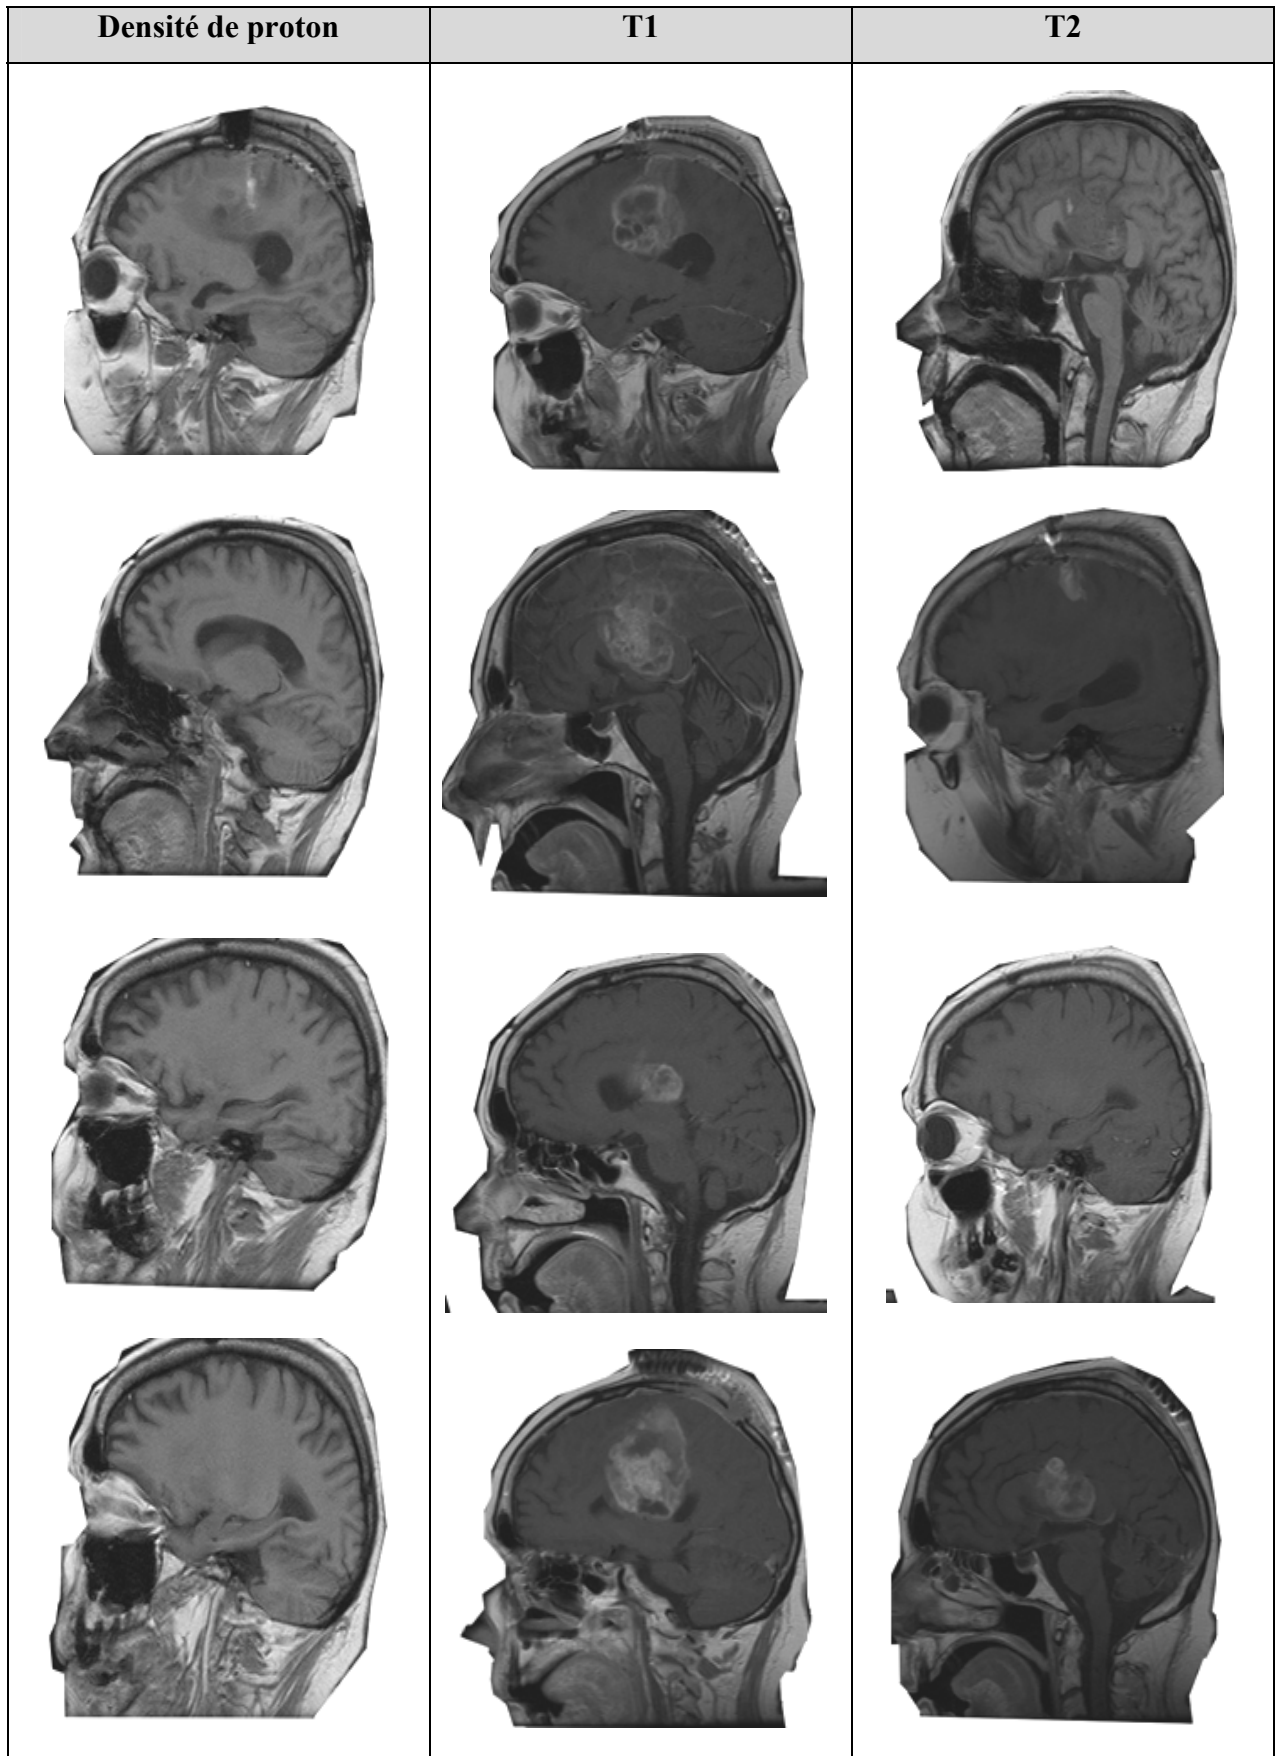


Figure 53 : Images originales : coupes sagittales (différentes pondérations Dp, T1, T2)




Figure 54 : Segmentation par FPCM : coupes sagittales (différentes pondérations T1, T2,Dp)

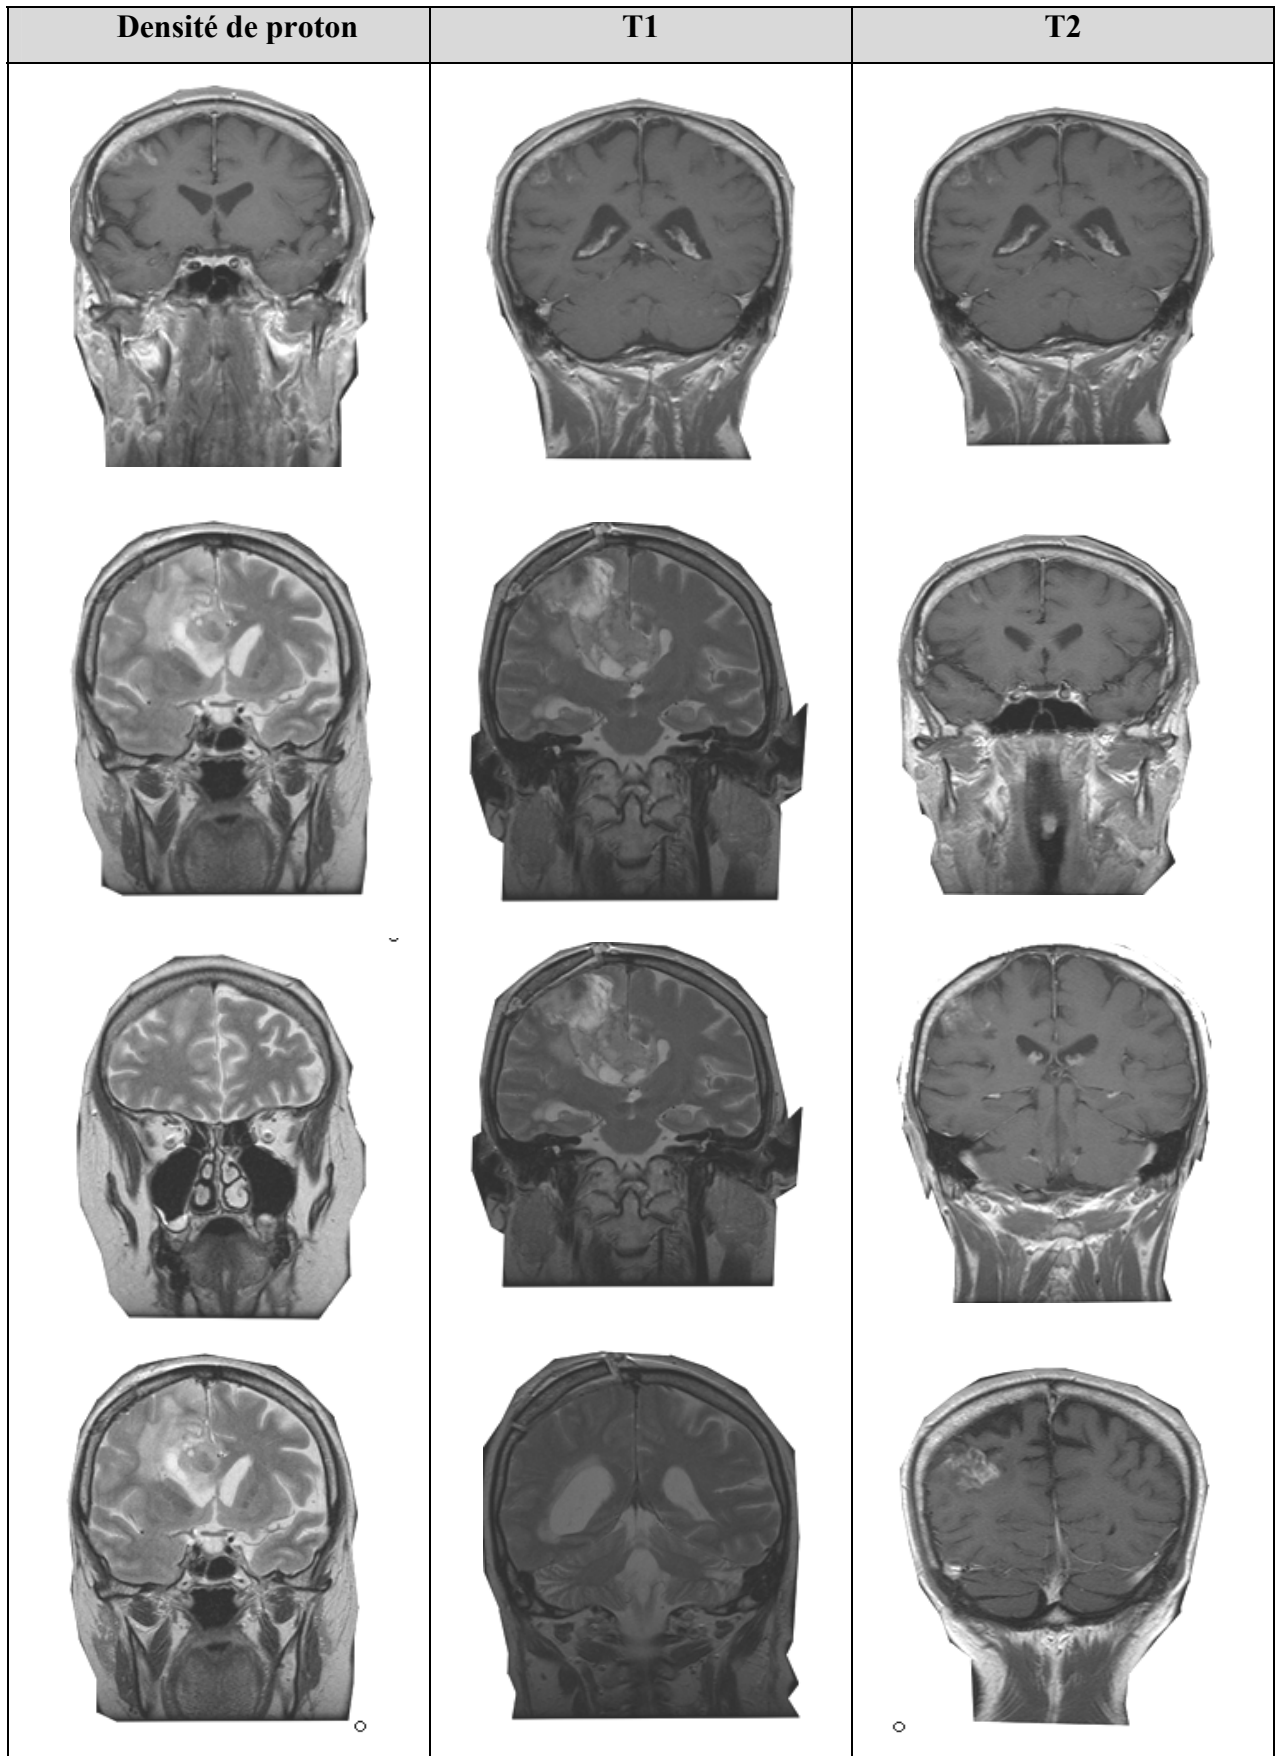


Figure 55 : Images originales : coupes coronales (différentes pondérations T1, T2,Dp)




Figure 56 : Segmentation par FPCM : coupes coronales (différentes pondérations T1, T2,Dp)

Images	Coupes		
	Axiales	Sagittales	coronales
1	2.34	1.27	1.17
2	2.30	1.21	1.19
3	2.51	1.19	1.23
4	2.35	1.20	1.22
5	1.25	1.26	1.22
6	1.05	1.15	1.24
7	1.37	1.17	1.18
8	0.54	1.21	2.19
9	1.24	1.20	1.13
10	1.26	1.15	1.19
11	2.01	1.20	1.20
12	1.18	1.1	1.25
13	0.47	1.26	1.14
14	1.16	1.23	1.21
15	1.15	1.12	1.20

Tableau 5 : Temps de segmentation en minutes pour un critère d'arrêt ($\epsilon = 0.05$).

Conclusion

En conclusion, on peut dire que nos algorithmes coopératifs pour la segmentation de l'encéphale sont robustes. Nous pourrions conclure, en comparant la segmentation par notre approche avec celles fournies par les approches classiques, que la qualité de la segmentation est en faveur des méthodes coopératives.

Malgré tous les avantages de l'approche développée, cette dernière souffre cependant du problème de temps d'exécution qui reste très élevé par rapport aux méthodes classiques. Ce problème est principalement lié à la taille des images (512*512) et la nature des calculs effectués sur ces dernières.

Conclusion générale

L'étude bibliographique menée au deuxième chapitre a montré la diversité des approches qui existent pour aborder la segmentation des images IRM cérébrales. Cette diversité nous a guidé à proposer une méthode hybride qui combine entre plusieurs algorithmes pour profiter des avantages de chacun, afin que la segmentation caractérise mieux les différents tissus cérébraux (matière grise, matière blanche, liquide céphalorachidien).

L'ensemble du travail que nous avons réalisé au cours de ce mémoire est fondé sur l'exploitation d'informations hétérogènes (complémentaires et parfois contradictoires) issues de deux approches de classification non supervisées. Dans un premier temps l'initialisation (la matrice des degrés d'appartenances et les centres de classes) est faite par l'algorithme FCM. Dans un second temps l'algorithme PCM est ensuite utilisé avec des nouvelles contraintes pour corriger le résultat provenant du FCM, cet algorithme permet entre autre de générer un degré d'appartenance absolu reflétant de manière exacte la réalité de distribution des pixels. Pour rendre l'algorithme robuste face aux données ambiguës et aberrantes nous avons proposer d'introduire la notion de rejet avec deux types de rejet : le rejet d'ambiguïté qui concerne les individus situés entre les frontières des différentes classes et le rejet d'aberrance concernant les individus dont les similarités par rapport à toutes les classes sont très éloignées, l'utilisation d'une telle technique permet de mesurer les degrés d'appartenance par rapport aux vrais centres.

Pour contrôler et/ou coordonner l'exécution des différentes phases du processus de segmentation, nous avons eu recours aux systèmes multi-agents. Notre processus de segmentation proposé fait donc intervenir, à différents niveaux, cinq agents chacun a des compétences spéciales, depuis l'agent superviseur qui gère toutes les interactions entre les agents à l'agent rejet d'aberrance qui rejette les individus les plus éloignés par rapport aux centres de classes.

Nous avons présenté les premiers résultats de notre travail qui consiste à utiliser plus d'un algorithme pour segmenter des images médicales en vue d'améliorer la qualité de la segmentation. La segmentation a été réalisée sur des IRM cérébrales bidimensionnelles, les résultats obtenus après segmentation sur un ensemble de données sont satisfaisants et comparés de façon favorable avec les résultats d'autres méthodes comme les algorithmes FCM, PCM sur le même ensemble de données, ce qui nous permet de dire, que l'utilisation

combinée de plusieurs algorithmes de segmentation travaillant en coopération permet de pallier aux problèmes rencontrés par l'utilisation d'un seul algorithme,

Cependant l'approche que nous avons proposée admet aussi des faiblesses concernant le temps d'exécution qui est trop long, l'implémentation des agents, la programmation des deux types de rejets, et l'évaluation de la segmentation.

La perspective qui pourrait être envisagée en réponse à la contrainte temporaire dans le cadre de futurs travaux est l'implémentation des calculs dans un environnement distribué .

Enfin, autres perspectives indépendantes des difficultés rencontrées au cours de ce mémoire sont :

- L'application des opérateurs de morphologie mathématique pour extraire le cerveau du crâne.
- L'utilisation du recalage pour les images de taille différente dans la segmentation multimodale.
- Développement d'un système expert capable de donner un diagnostic à travers les résultats de classification effectuée par notre application.
- Utilisation d'un autre mode de coopération (régions, contours, ...etc).
- L'introduction des connaissances *a priori* des médecins pour guider et corriger les résultats.
- Développer une ontologie spécifique à la segmentation des IRM cérébrales.

Annexe : Le format DICOM

1. Historique⁶

Il a été créé en 1985 par l'ACR (*American College of Radiology*) et la NEMA (*National Electric Manufacturers Association*) dans le but de standardiser les données transmises entre les différents appareils de radiologie. Ce standard définit un format de fichier mais aussi un protocole de transmission des données (basé sur TCP/IP).

L'objectif de la norme DICOM (*Digital Imaging and Communications in Medicine*) est de faciliter les transferts d'images entre les machines de différents constructeurs. En effet, avant la généralisation de ce format, chaque constructeur de matériel d'imagerie utilisait un format de données propriétaire, qui génère des problèmes importants de gestion et de maintenance (incompatibilités, coût, perte d'information) dans les établissements de santé.

Le suivi médical des patients, surtout en cas de pathologie lourde nécessitant souvent le transfert d'un établissement de santé à un autre en fonction des moyens et compétences disponibles, il a directement bénéficié de l'instauration de cette norme. Les images au format Dicom accompagnant les dossiers médicaux sont lisibles sur tout matériel informatique compatible, et rendent obsolète le transport des clichés par les moyens de communication traditionnels, principalement les envois par courrier.

2. Définition

Le terme "DICOM" (*Digital Imaging and Communications in Medicine*) peut être utilisé pour parler du format de fichier des images médicales, mais aussi d'un protocole de communication en réseau. L'idée initiale était de définir une plateforme numérique commune aux images radiologiques (qui auparavant étaient "imprimée" sur des planches argentiques au coût de revient élevé), mais à mesure de l'acceptation de cette norme et de l'évolution des réseaux d'images, les spécifications DICOM se sont étendues vers les protocoles de télécommunication (échanges, sécurisation,...etc). De nouvelles définitions sont ajoutées chaque année car la radiologie et les modalités (scanner, IRM,...etc) évoluent également. Actuellement, nous sommes à la version 3.0 de la norme.

3. Pourquoi DICOM ?

Un Service de radiologie produit plusieurs milliers d'images chaque jour, ainsi, un scanner, travaillant au rythme de 3 patients par heure produit environ 150 images par heures, et il n'est

⁶ Toute la documentation sur DICOM est sur : <http://medical.nema.org/>

pas possible de classer ces images dans un format courant de type JPEG ou GIF car il aurait un risque de pertes des données démographiques de l'images, (nom du patient, type d'examen, hopital, date d'examen, type d'acquisition... etc). Le format DICOM permet de rendre unique chaque image produite et de leur associer des informations spécifiques. Ainsi chaque image est autonome, si elle est perdue, reproduite ou renommée, il est toujours possible d'identifier formellement son origine, le patient, la date, la série d'où elle provient, les paramètres d'acquisition... etc.

Le format n'est pas rigide, il contient des informations obligatoires et d'autres optionnelles. Plusieurs numéros d'identification uniques UID ("Unique Identifier") sont générés automatiquement par les machines DICOM et obligatoirement présents dans chaque image DICOM. Il ne peut pas exister deux UID identiques pour désigner des informations différentes, ceci quelque soit la machine et sa localisation, ainsi l'UID d'une série d'images est spécifique à une date, un patient, une étude, un hôpital et une machine donnée. Cette identification est nécessaire non seulement pour des raisons médicales et médico-légales, mais aussi pour permettre aux machines la formation et la gestion de bases de données.

4. Caractéristiques de la norme DICOM [IVA 06]

- **Vocabulaire contrôlé**

DICOM utilise une norme universelle qui est la norme SNOMED mis au point par les anatomo-pathologistes (*Systemized Nomenclature for MEDicine*). Ainsi le vocabulaire est identique d'une machine à l'autre.

- **Facilité de la modification et la révision des documents**

La norme peut être facilement révisée et modifiée grâce à la multiplicité des documents de référence. La rédaction de cette norme suit des directives strictes établies par le comité ISO.

- **Adaptabilité aux autres spécialités médicales**

Ce format est déjà adopté par les cardiologues, les dentistes, les anatomopathologistes et les gastro-entérologues.

- **Une norme universelle**

La norme DICOM est prédestinée en quelque sorte à être universelle. Pour le reste c'est l'effort de l'utilisateur qui est mis en cause car celui-ci a tout l'intérêt d'acheter des systèmes DICOM ouverts c'est-à-dire :

Connectables par un réseau TCP/IP Ethernet et/ou pouvant sortir les informations sous la forme d'un média numérique (CD Rom, disques Zip, disques optiques effaçables...). Soulignons aussi le fait que les équipements anciens ne sont pas souvent à la norme DICOM.

- **Une norme orientée objet**

La norme DICOM est orientée objet, cela signifie que chaque objet DICOM (le plus souvent une image) contient à la fois les informations (le nom du patient, les pixels de l'image...) et les méthodes (ou fonctions) que doit subir cette information.

Exemple :

- Information : une image IRM ou scanner ..., en langage DICOM: Information Object.
- Méthodes : à imprimer et/ou à sauvegarder, en DICOM un Service.

5. Organisation des données dans un fichier DICOM

L'information est organisée sous une forme séquentielle. Ceci est inspiré par la sauvegarde des données sur une bande magnétique. Les données correspondantes aux pixels de l'image sont précédées par les d'autres données techniques et démographiques.

Chaque information élémentaire est constituée de 3 champs de données. Le premier champ est codé sur 8 octets, il s'agit d'une "balise" ou "tag", répertoriée dans le dictionnaire DICOM, qui indique le type d'information qui va suivre. Le deuxième champ de 8 octets indique la longueur de l'information contenue dans le 3ème champs, jusqu' à la balise suivante.

Ainsi une information élémentaire est formée par 3 champs de données successifs :

- Premier champs: 8 octets correspondant aux balises du dictionnaire (exemple âge du patient : 0x0010 1010 en hexadécimal)
- Deuxième champs : 8 octets correspondants la longueur en octet du champs suivant (exemple âge codé sur 2 octets : 0x0000 0002)
- Troisième champs de longueur variable, déterminé par le champ précédant correspondant à l'information identifiée par les premiers champs.

Exemple : Codage de l'identification du patient :

Si on rencontre dans un flux de données DICOM les éléments suivants en hexadécimal:

00 10 00 20 00 00 00 0A 4A 6F 68 6E 5E 48 65 6E 72 79

Ce flux se décompose de la manière suivante :

4 octets balise groupe	4 octets balise élément	8 octets longueur l du champ suivant	Longueur variable l, information :
0010	0020	0000000A	4A 6F 68 6E 5E 48 65 6E 72 79
données codant l'information du patient	l'information sera le nom du patient	Indique la longueur du champ suivant.	Semchedine Moussa

6. Quelques éléments importants du format DICOM

Group Length, Comments, Recognition Code, Study Date, Series Date, Acquisition, Image date, Study Time, Series Time, Acquisition Time, Image Time, Modality, Patient Name, Patient ID, Patient Birthdate, Patient Sex, Patient Age, Contrast/Bolus Agent, Repetition time Echo Time, Rows #nombre de lignes, Columns #nombre de colonnes, Pixel Size

7. Modalités supportées par DICOM

AS	Angioscopy (retired)	ES	Endoscopy
AU	Audio	FA	Fluorescein angiography (retired)
BI	Biomagnetic imaging	FS	Fundoscopy (retired)
CD	Color flow Doppler	GM	General Microscopy
CF	Cinefluorography (retired, now in RF)	HC	Hard Copy
CP	Culposcopy (retired)	HD	Hemodynamic Waveform
CR	Computed Radiography	IO	Intra-oral Radiography
CS	Cystoscopy (retired)	IVUS	Intravascular Ultrasound
CT	Computed Tomography	LP	Laparoscopy (retired)
DD	Duplex Doppler	LS	Laser surface scan
DF	Digital fluoroscopy (retired, now in RF)	MA	Magnetic Resonance angiography (retired)
DG	Diaphanography	MG	Mammography
DM	Digital microscopy (retired)	MR	Magnetic Resonance
DS	Digital Subtraction Angiography (retired, now in XA)	MS	Magnetic Resonance spectroscopy (retired)
DX	Digital Radiography	NM	Nuclear Medicine
EC	Echocardiography (retired)	OP	Ophthalmic Photography
ECG	Electrocardiography	OT	Other
EPS	Cardiac Electrophysiology	PR	Presentation State
AS	Angioscopy (retired)	PT	Positron emission tomography (PET)
AU	Audio	PX	Panoramic X-Ray
BI	Biomagnetic imaging	RF	Radio Fluoroscopy
CD	Color flow Doppler	RG	Radiographic imaging (conventional film/screen)

Tableau 6 : Liste des modalités supportées par DICOM.

8. Classes de Service actuellement disponibles dans la norme

Classes de Service	Type de Service
<ul style="list-style-type: none"> • Verification (Verification Service Class) 	- Utilisé pour les tests, permet de savoir si les machines "s'entendent" mutuellement, cette classe n'est pas associée à un objet DICOM , elle renvoie l'information sous la forme d'un écho. (C-ECHO)
<ul style="list-style-type: none"> • Storage(Storage Service Class) • Media Storage Service Class 	- Permet le transfert et la sauvegarde des images entre deux entités DICOM. (CR,CT,MR Storage Service Class) - Il existe une variante : Media Storage Service Class qui spécifie les échanges entre 2 machines par l'intermédiaire d'un média (CD rom , disquettes etc...)
<ul style="list-style-type: none"> • Query/Retrieve 	- Implémente des commandes types : FIND, MOVE, GET . FIND permet de demander une liste d'image, MOVE et GET permettent d'initier un transfert, qui sera réalisé effectué via la classe "Storage Service Class"
<ul style="list-style-type: none"> • Study Contents Notification 	- Utilisée pour notifier l'arrivée d'une nouvelle image ou série d'images, peut être utilisée pour initier un transfert ou vérifier si le transfert d'une série d'image est complet.
<ul style="list-style-type: none"> • Print Management 	- Permet la connection avec un reprographe, spécifie le type d'image , (Couleurs, niveaux de gris etc..)
<ul style="list-style-type: none"> • Patient Management 	- Permet d'interfacer la machine au réseau hospitalier PACS ou HIS/RIS (<i>Hospital Information Service/ Radiological Information Service</i>) Gestion des données des patients, démographie, admission et sortie des patients
<ul style="list-style-type: none"> • Study Management 	- Création, gestion de rendez-vous, suivi des examens.
<ul style="list-style-type: none"> • Result Management 	- Permet la gestion des résultats des examens

Tableau 7 : Différentes classes de la norme DICOM

Remarque : L'extension d'un fichier DICOM est .dcm

9. Conclusion

Bien que l'adaptation d'un équipement radiologique ou médicale à la norme DICOM soit coûteuse, elle permet :

- D'assurer une compatibilité du matériel avec les équipements futurs,
- De garantir la pérennité des images (DICOM est maintenant universel)
- De choisir un outil adapté à chaque demande.

DICOM stimule donc la concurrence entre les différents constructeurs et assainit le marché en libérant les utilisateurs des contraintes techniques ou financières imposées par certains constructeurs.

- [ATT97] A. Attoui 1997. « *Les systèmes multi-agents et le temps réel* ». Edition Eyrolles.
- [BAD92] BADDELEY A, 1993 “*An Error Metric for Binary Images, Robust Computer Vision*”, Graphics and Image Processing, Vol. 26, No. 2, pp. 375-376.
- [BAI00] C Baillard, C Barillot, P Boutheymy Robust 2000. « *Adaptive Segmentation of 3D Medical Images with Level Sets* » Research Report - INRIA, Rennes, France, - irisa.fr.
- [BAR00] BARRA V, BOIRE JY, 2000 “*Tissue Characterization on MR Images by a possibilistic Clustering on a 3D Wavelet Representation*”, Journal of Magnetic Resonance Imaging, **11**:267-278.
- [BAR99] Barra.V (1999), «*Segmentation floue des tissus cérébraux en IRM 3D: une approche possibiliste versus autres méthodes*». Thèse doctorat. Université Blaise Pascal.
- [BAU98] Brandt M, Bohan T, Kramer L, Fletcher J, 1994. “*Estimation of CSF, White and Gray Matter Volumes in Hydrocephalic Children Using Fuzzy Clustering of MR Images*”, Computerized Medical Imaging and Graphics, **18**:25-34.
- [BEL98] Bellet, F. 1998. « *Une approche incrémentale, coopérative et adaptative pour la segmentation des images en niveaux de gris* », Thèse de doctorat, Institut National Polytechnique de Grenoble.
- [BEN94] Bensaid A, Hall L, Bezdek J, Clarke L, 1994. “*Fuzzy Cluster Validity in Magnetic Resonance Images*”, SPIE Medical Imaging, **2167**:454-464.
- [BEZ81] J .C. Bezdek. 1981. “*Pattern Recognition with Fuzzy Objective Function Algorithms*”, Plenum Press, New-York .
- [BEZ93] J .C Bezdek.J 1993. «*Review of MR Image Segmentation Techniques using Pattern Recognition*», Medical Physics.
- [BIT90] J. Bittoun. Basic 1998. « *Principles of Magnetic Resonance Imaging* ». In 15th Annual Scientific Meeting of the European Society for Magnetic Resonance in Medicine and Biology, 45–53. Geneva. Springer.
- [BLO96] Bloch, I. 1996. “*Information combination operators for data fusion : A comparative review with classification*”. IEEE Trans. Systems, Man, and Cybernetics **26**(52-67).
- [BOI04] Olivier Boissier, Sylvain Gitton, Pierre Glize. 2004. « *Caractéristiques des systèmes et des applications. Dans : Systèmes multi-agents* ». Editions TEC DOC, p. 25-54, V. 29.
- [BOI93] Boissier, O. 1993. “ *Problème du contrôle dans un système intégré de vision*”, Thèse de doctorat, Institut National Polytechnique de Grenoble.
- [BOM90] Bomans, M. Hohne, K.-H. Tiede, U. Riemer, M 1990. « *Segmentation of MR images of the head for 3-D display* ». Medical Imaging, IEEE Transactions **177-183**
- [BOS03] Marcel Bosc 2003 «*Contribution à la détection des changements dans les séquences IRM 3D multimodales* » Thèse de doctorat. Université Louis Pasteur Strasbourg
- [BOU99] Boucher, A. 1999. “*Une approche décentralisée et adaptative de la gestion d'information en vision*”. Thèse de doctorat, Université Joseph Fourier, Grenoble.
- [BOZ94] I. Bozma and J.S. Duncan. « *A Game-Theoretic Approach to Integration of Modules* ». IEEE Transactions on Pattern Analysis and Machine Intelligence, **16**(11), pp. 1074–1086.
- [BRI01] J.P. Briot et Yves Demazeau. 2001. « *Principes et architecture des systèmes multi-agents* ». Edition Hermès.
- [BRO91] Brook, R. A. 1991. “*Intelligence without representation*”. Artificial Intelligence **47**: 139-159.
- [BRU93] Brummer, M.E.; Mersereau, R.M.; Eisner, R.L.; Lewine, 1993. « *Automatic detection of brain contours in MRI data sets* » Medical Imaging, IEEE Transactions on (12), Page(s):153 – 166.
- [CAG93] Cagnoni S 1993. « *Neural network segmentation of magnetic resonance spin echo images of the brain* », Journal of Biomedical Engineering.
- [CHA99] A. Chakraborty and J.S. Duncan. 1999. « *Game Theoretic Integration for Image Segmentation* ». IEEE Transactions on Pattern Analysis and Machine Intelligence, **21**(1), pp. 12–30.
- [CHE04] Y. Cherfa, Assia Jaillard A. Cherfa , Y. Kabir 2004 . « *Segmentation coopérative d'images RMN cérébrales : Application à la caractérisation des accidents vasculaires cérébraux* ». Journées d'études sur l'imagerie médicale JETIM Blida.
- [CHE95] Y. Cheng, , 1995. « *Mean-shift, mode seeking, and clustering* », IEEE Transactions on Pattern Analysis and Machine Intelligence, (17), pp. 790-799
- [CHR02] Jean-Christophe Routier et Eric Wegrzynowski, 2003. « *Débuter la programmation Scheme* » Editions Vuibert.
- [CLA93] Clarke L, Velthuizen R, Phuphanich S, 1993. « *MRI : Stability of three Supervised Segmentation Techniques* », Magnetic Resonance Imaging, **11**:95-106.
- [CLA94] : CLARK M 1994. « *MRI Segmentation Using Fuzzy Clustering Techniques* », IEEE Engineering in Medicine and Biology.
- [COC95] S. Philipp, J-P. Cocquerez, 1993 « *Fusion de régions sur critères géométriques* », 14ème Colloque GRETSI.
- [CRO93] Crowley, J. and H. Christensen 1993. “*Vision as Process*”, Springer.
- [DAV90] Dave R, 1990. “*Fuzzy Shell Clustering and Application to Circle Detection in Image Processing*”, International Journal of General Systems, **41**:343-355.
- [DAV92] R.N . Dave. 1992 . “*Boundary detection through fuzzy clustering* “. Proc. 1st IEEE International Conference on Fuzzy Systems, San Diego.
- [DEL86] De la Paz R, Bernstein R, Hanson W, Walker M, 1986. “*Approximate Fuzzy C-Means Cluster Analysis of Medical MR Images Data.*”. A System for Medical Research and Education, IEEE Transactions on Geosciences and Remote Sensing, **25**:815-824.

- [DEL91] S. Dellepiane, G. Venturi, and G.1991 "A fuzzy model for the processing and recognition of MR pathological images". In Lecture notes in computer science, IPMI proceedings, 444–457. Springer.
- [DER87] R. Deriche, 1987. "Using Canny's Criteria To Derive A Recursive Implemented Optimal Edge Detector", International journal of computer vision, pp. 167-187.
- [DIG94] Di Gesu V, Romeo L, 1994. "An Application of Integrated Clustering to MRI Segmentation", Pattern Recognition Letters, 45:731-738.
- [DUC01] Duchesnay, E. 2001. "Agents situés dans l'image et organisés en pyramide irrégulière. Contribution à la segmentation par une approche d'agrégation coopérative et adaptative", Thèse de doctorat, Université de Rennes 1.
- [DUD73] Duda.R « Pattern Classification and Scene Analysis ». Edition Wiley 1973.
- [EAL01] Ealet, F. 2001. "Une architecture multi-agent pour la détection, la reconnaissance et l'identification de cibles". Thèse de doctorat, Université Joseph Fourier, Grenoble, 2001.
- [FEB95] J. Ferber 1995 « Les systemes multi-agents, vers une intelligence collective » Editeurs: G.M.P.
- [FEB99] J.Ferber 1999 « Multi-Agent Systems: an Introduction to Distributed Artificial Intelligence » Edition Wesley.
- [FLO90] P. Le Floch-Prigent, M. Molho, and H. Outin. 1990. « Imagerie de l'encéphale, Anatomie et observations cliniques. » Laboratoires Sandoz.
- [GAR00] Germond L., Dojat M. , Taylor, C. & Garbay, C. 2000. "A cooperative framwork for segmentation of MRI brain scans", Artificial Intelligence in Medicine, 20(1),
- [GAT89] Geva B, Ath I 1989. "Unsupervised Optimal Fuzzy Clustering", IEEE Transactions on Pattern Analysis and Machine Intelligence, 11:773-781.
- [GER98] L. Germond. 1998. « Coopération entre processus guidés par les données et les modèles pour la segmentation en IRM ». Technical Report RR1005-I, TIMCIMAG.
- [GER99] Germond Laurence 1999. « Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale » Thèse de doctorat L'université Joseph Fourier.
- [GUN01] Gunes Veyis 2001.« Reconnaissance des formes évolutives par combinaison, coopération et sélection de classifieurs » . Thèse de doctorat . Université de La Rochelle
- [HAA90] Haacke E, Tkach J, 1990 "Fast MR Imaging : "Techniques and Clinical Applications", AJR 155, pp. 951-964.
- [HAR04] R. Haroun, L. Hamami, F. Boumghar 2004. « Segmentation d'images médicales IRM, par un système hybride flou - croissance de régions, dans un système multi-agents » Journées d'études sur l'imagerie médicale JETIM Blida.
- [HEL97] Karsten Held, Elena Rota Kops, Bernd J. 1997. « Markov Random Field Segmentation of Brain MR Images » IEEE Transactions on Medical Imaging, 16:878-886.
- [IVA06] Ivanov Ivan, Quoirin Louise, Ben-dhia aymen, Chaieb Nizar 2006. « Interface de visualisation d'images échographiques ». Rapport de projet
- [JAG97] Jaggi C 1997. « Approche Markovienne pour la Segmentation 3D des Tissus Cérébraux en IRM » Colloque GRETSI.
- [JOH96] B. Johnston, M.S. Atkins, B. Mackiewicz, and M. Anderson. 1996. « Segmentation of Multiple Sclerosis Lesions in Intensity Corrected Multispectral MRI ». IEEE Transactions on Medical Imaging, 15(2), pp. 154–169.
- [JUS88] Just M, Thelen M, Tissue 1988. « Characterization with T1, T2 and Proton Density Values: Results in 160 Patients with Brain Tumors », Radiology, 169:779-785.
- [KAP90] I. Kapouleas 1990. « Automatic detection of white matter lesions in magnetic resonance brain images ». Computer Methods and Programs in Biomed.
- [KAP96] T. Kapur, W. Eric, L. Grimson, W.M. Wells, and R. Kikinis. 1996. « Segmentation of brain tissue from magnetic resonance images ». Medical Image Analysis, 1(2), pp. 109–127.
- [KAR93] Kara Falah R, Bolon P. 1993, « Mesure de similarité entre deux segmentations », In Colloque GRETSI XIV, Juan-Les-Pins, pp. 763-766,.
- [KAS88] M Kass, A Witkin, D Terzopoulos 1988 « Snakes: Active contour models ». International Journal of Computer Vision, Springer
- [KAU90] Kaufman L, Rousseeuw P, 1990. "Finding Groups in Data, an Introduction to Cluster Analysis". Edition Wiley.
- [KIV84] Kiviniitty K, 1984. "NMR relaxation Times in NMR Imaging", Annals of Clinical Research, 40 : 4-6.
- [KRI96] Krishnapuram R, Keller J. 1996 . "The Possibilistic C-Means Algorithm: Insights and Recommendations". IEEE transactions on Fuzzy Systems.
- [LAN99] S. Langlois, M. Desvignes, J.M. 1999. « A simple Approach to Correcting the effects of non-linear gradient fields ». Journal of Magnetic Resonance Imaging, 9(6), pp. 821–831.
- [LAR06] Morin Yves 2006 « Larousse médical » édition larousse.
- [LEF94] Lefèvre, V. 1994. "Système multi-agents d'aide à la photo-interprétation sur architecture multiprocesseurs.", Thèse de doctorat, Université Paris Sud.
- [LIU99] Liu, J. and Y. Y. Tang 1999. "Adaptive Image Segmentation With Distributed Behavior-Based Agents". IEEE Trans. Pattern Analysis And Machine Intelligence 21(6): 544-551.
- [MAG99] Magnotta V 1999. « Measurement of Brain Structures with Artificial Neural Networks: 2D and 3D Applications », Radiology, 211:781-790.
- [MAH80] D. Mahr. 1980. « Theory of edge detection. In Proceedings of the Royal Society of London », pages 197–217.

- [MAN02] R. Mandiau, 2002. « *Organisation et applications des SMA* ». Edition Hermès.
- [MAR82] Marr, D. 1982. "Vision", W.H. Freeman.
- [MAS99] Masulli F, Schenone A, 1999. "A Fuzzy Clustering based Segmentation System as Support to Diagnosis in Medical Imaging", *Artificial Intelligence in Medicine*, 16:129-147.
- [MAT65] G. Matheron. 1965. « *Random Sets and Integral Geometry* ». Edition Wiley
- [MEN98] Michel Ménard . 1998. "The fuzzy c+2 means : Solving The Extended Ambiguity Reject in Clustering" . In *IEEE Transactions on fuzzy systems*, vol. 1, N° .2, pages 195-203.
- [MOH99] Mohamed F, Vinitski S, Faro S, Gonzales C, Mack J, Iwanaga T, 1999. « *Optimization of Tissue Segmentation of brain MR Images based on multispectral 3D Feature Maps* », *Magnetic Resonance Imaging*, 17:403-409.
- [MOU05] A. Moussaoui, K. Benmahamed, N. Ferahta et V. Chen 2005. « *A new fuzzy clustering based mean_shift procedure applied to brain image segmentation* ». *Asian Journal of Information Technology*, 4(6):590-595.
- [PEN99] Peña J 1999. « *An empirical Comparison of four Initialization Methods for the k-means Algorithm* », *Pattern Recognition Letters*.
- [PHI95] Philipps W, Velthuizen R, Phuphanich S, Hall L, Clarke L, Silbiger M, 1995. "Application of Fuzzy C-Means Algorithm Segmentation Technique for Tissue Differentiation in MR Images of a Hemorrhagic Glioblastoma Multiforme", *Magnetic Resonance Imaging*, 13:277-290.
- [PIT90] Pitrat J, 1990 « *Métaconnaissance* », Hermès , 402p.
- [PRE70] J.M.S Prewitt. 1970. « *Picture Processing and Psychophysics* » Academic Press.
- [ROB65] G. Roberts 1965. « *Machine perception of three-dimensional solids* », Edition Cambridge.
- [RUS97] S. Russell 1997 « *Artificial Intelligence - A Modern Approach* ». In *Proceedings of Sixth International World Wide Web*.
- [SCH01] H.G. Schnack 2001 « *Automatic Segmentation of the Ventricular System from MR Images of the Human Brain* » *Neuroimage*. 14(1 Pt 1):95-104.
- [SEM06] Semchedine M, Toumi L, Moussaoui A, 2006 "Nouvelle Approche de Classification Multimodale Hybride d'Images IRM dans un SMA". *Journées internationales de l'informatique graphique JIG .Tébessa*.
- [SER82] J. Serra. 1982. « *Image Analysis and Mathematical Morphology* », volume 1. Academic Press, London.
- [SHO 93] Yoav Shoham Stanford Univ., Stanford, CA1993. « *Agent-oriented programming* » *Artificial Intelligence archive Volume 60*, Pages: 51 - 92
- [SHU 99] J.A. Shufelt. 1999. "Performance Evaluation and Analysis of Monocular Building Extraction from Aerial Imagery". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(4), pp. 311-326.
- [SLE 98] J.G. Sled, A.P. Zijdenbos, and A.C. Evans 1998. « *A Nonparametric Method for Automatic Correction of Intensity Nonuniformity in MRI Data* ». *IEEE Transactions on Medical Imaging*, 17(1), pp. 87-97.
- [SOB78] I. Sobel. 1978. « *Codage des images binaires et détection des contours* » *Image Processing*.
- [SUC99] Suckling J 1999. « *A modified Fuzzy Clustering Algorithm for Operator Independent Brain Tissue Classification of Dual Echo MR Images* » *Magnetic Resonance Imaging*.
- [TEO97] P.C. Teo, G. Sapiro, and B. Wandell. 1997. « *Creating Connected Representations of Cortical Gray Matter for Functional MRI Visualization* ». *IEEE Transactions on Medical Imaging*, 16(6), pp. 852-863.
- [THI97] Thiran J. P. ; Warscotte V. ; Macq B 1997. « *A queue-based region growing algorithm for accurate segmentation of multi-dimensional digital images* »; *Signal processing* vol. 60, no1, pp. 1-10.
- [VEL93] Velthuizen R 1993. « *Unsupervised Fuzzy Segmentation of 3D Magnetic Resonance Brain Images* » *Proc. SPIE Vol. 1905*, p. 627-635, *Biomedical Image Processing and Biomedical Visualization*
- [VEL95] Velthuizen R 1995. « *Unsupervised Measurement of Brain Tumor Volume on MR Images* ». *Journal of Magnetic Resonance Imaging*.
- [VIN91] Vinnet L. 1991, « *Segmentation et mise en correspondance de régions de paires d'images stéréoscopiques* », Université de Paris IX-Dauphine..
- [VIN98] Vinitski S 1998. « *Validation of Tissue Segmentation Based on a 3D Feature Map Using Both a Hamster Brain Tumor Model and Stereotactically Guided Biopsy of Brain Tumors in Man* » *Journal of Magnetic Resonance Imaging*.
- [VIN99] Vinitski S 1999. « *Fast Tissue Segmentation Based on a 4D Feature Map in Characterization of intracranial Lesions* », *Journal of Magnetic Resonance Imaging*
- [WAR95] S. Warfield, J. Dengler, J. Zaers, and al. 1995. « *Automatic identification of gray matter structures from MRI to improve the segmentation of white matter* ». *Journal of Image Guided Surgery*, 1, pp. 326-338.
- [WAR02] Warking, J. 2002. « *Délinéation des aires visuelles réiotopiques chez l'homme par IRM fonctionnelle* », Thèse de doctorat, Université Joseph Fourier, Grenoble.
- [WEI99] Weiss, G 1999. « *Multiagent Systems. A Modern Approach to Distributed Artificial Intelligence* », The mit press, Cambridge, massachusetts.
- [WEL96] W.M. Wells, L. Grimson, R. Kikinis, and F.A. Jolesz. 1996. « *Adaptative Segmentation of MRI data* ». *IEEE Transactions on Medical Imaging*, 15(4), pp. 429-442.
- [WOO 00] M. Wooldrige 2000. « *Reasoning about Rational Agents* ». MIT Press.
- [WOO 01] : M. Wooldrige 2001. « *Multiagent Systems - A Modern Approach to Distributed Artificial Intelligence* » MIT Press
- [ZAD 78] Zadeh L, 1978. "Fuzzy Sets as a Basis for Theory of Possibility", *International Journal of Fuzzy Sets and Systems*, 1:3-28.

ملخص:

في هذه المذكرة ذكرنا مختلف طرق تقسيم صور الرنين المغناطيسي للدماغ. مع تعدد هذه الطرق لاحظنا أنه لا توجد طريقة مثلى و كل طريقة تعطي نتائج مرضية في سياق معين فقط و هو ما دفعنا إلى التفكير في الطرق المتعاونة التي تنسق بين مختلف المعلومات من أجل إستغلال التكامل الموجود بين مختلف الطرق.

الطريقة المتبعة تنسق بين خوارزمي المتوسطات الضبابية الذي يحسب درجة الإلتحاق بطريقة نسبية و خوارزمي المتوسطات الممكنة الذي يديرها بطريقة مطلقة, و من أجل التقليل من تأثير الأفراد (البيكسال) الغامضة و الأفراد البعيدة أدخلنا مفهومي الرفض : الأول متعلق برفض الأفراد التي توجد بين مختلف الأقسام و الثاني متعلق بالأفراد البعيدة كل البعد عن وسط القسم. من أجل مراقبة و تنسيق مختلف مراحل التقسيم فرضنا النظم متعددة الأعوان التي لها خاصية تعلم مهارات جديدة.

مفاتيح: التقسيم, التصنيف الأوتوماتيكي, خوارزمي المتوسطات الضبابية, خوارزمي المتوسطات الممكنة, الطرق المتعاونة, صور الرنين المغناطيسي.

Résumé :

Dans ce mémoire on a essayé, de mettre en oeuvre un état de l'art sur les différentes méthodes de segmentation d'images IRM cérébrales. Malgré la diversité de ces méthodes, nous avons remarqué qu'il n'existe pas une méthode de segmentation optimale, et chaque méthode donne un résultat satisfaisant dans un contexte particulier, ce qui nécessite la mise en oeuvre de la coopération de différentes méthodes, qui doit combiner plusieurs sources d'informations pour accomplir une tâche donnée, et tirer parti des complémentarités entre méthodes.

Notre approche consiste à faire la coopération entre l'algorithme FCM (C-moyennes floues) dont la contrainte d'appartenance d'un individu à une classe est gérée d'une manière relative et l'algorithme possibiliste PCM (C-means possibilistes) qui relâche cette contrainte reflétant ainsi de manière exacte la réalité de la distribution des individus. Afin de diminuer l'influence des données aberrantes et ambiguës, nous avons introduit deux concepts de rejet : le rejet d'ambiguïté qui concerne les individus situés entre les frontières des différentes classes et le rejet d'aberrance concernant les individus qui sont très éloignés par rapport à toutes les classes.

Pour contrôler et/ou coordonner l'exécution des différentes phases du processus de segmentation, nous avons eu recours aux systèmes multi-agents qui présentent la faculté d'apprentissage de nouvelles compétences pour gérer l'incertitude liée aux informations manipulées (images IRM)

Mots clé : Segmentation, Classification non supervisée, c-moyennes floues, c-moyennes possibiliste
Coopération des classifieurs, Imagerie par Résonance Magnétique

Abstract:

In this memory we present different methods of segmentation of cerebral images MRI (Magnetic resonance imaging). In spite of diversity of these methods, we have noticed that there is not an optimal method of segmentation, and each method gives result satisfactory in particular context, which requires the implementation of the co-operation of various methods, which must combine several sources of information to benefit from the complementarities between methods.

Our approach consists in cooperating between the algorithm FCM (Fuzzy C-Means) whose constraint of membership of an individual to a class is relative and the algorithm possibilist PCM (Possibilistic C-means) which slackens this constraint thus reflecting in an exact way the reality distribution of the individuals.

In order to make the algorithm more robust for the ambiguous and the aberrant data, two types of rejections were introduced: the rejection of ambiguity and the rejection of aberrance. We test the results on images MRI in which we proved the convergence of our algorithm for the various anomalies which these images can have.

In order to coordinate and control the different steps of segmentation, a multi-agents system MAS is set then for accelerates the treatment.

Key words: Segmentation, Clustering, Fuzzy c-means, posibilist c-means, Cooperation of classifieurs, Resonance Magnétique imaging.