



HAL
open science

Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale

Laurence Germond

► **To cite this version:**

Laurence Germond. Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale. Interface homme-machine [cs.HC]. Université Joseph-Fourier - Grenoble I, 1999. Français. NNT: . tel-00004835

HAL Id: tel-00004835

<https://theses.hal.science/tel-00004835>

Submitted on 18 Feb 2004

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

UNIVERSITE JOSEPH FOURIER-GRENOBLE 1
SCIENCES & GEOGRAPHIE

THESE

pour obtenir le grade de

DOCTEUR DE L'UNIVERSITE JOSEPH FOURIER

Discipline : Informatique

Présentée et soutenue publiquement par

GERMOND LAURENCE

Le 11 octobre 1999

**TROIS PRINCIPES DE COOPERATION POUR LA SEGMENTATION EN
IMAGERIE DE RESONANCE MAGNETIQUE CEREBRALE**

Directeur de thèse : GARBAY Catherine

COMPOSITION DU JURY :

M. Christian BARILLOT,	Examineur
Mlle Isabelle BLOCH,	Rapporteur
M. Yves CHIARAMELLA,	Président
M. Michel DOJAT,	Invité
Mme Marinette REVENU,	Rapporteur

Remerciements

Je tiens à remercier Catherine Garbay qui a accepté de diriger ces travaux de recherche depuis le DEA jusqu'à la fin de cette thèse. Elle m'a initié à la recherche et permis de progresser tout au long de ces quatre années.

Je remercie également Michel Dojat pour avoir accepté de collaborer avec nous. Ses compétences en IRM fonctionnelle et ses méthodes de recherche nous ont permis d'avoir toujours le souci du travail bien mené.

Je remercie aussi le Pr. Taylor qui a accepté de me recevoir dans son laboratoire de Manchester au cours de ma thèse. Les mois passés sous sa direction ont été très fructueux et ont permis une ouverture vers d'autres méthodes de travail.

Je remercie Isabelle Bloch et Marinette Revenu d'avoir accepté de rapporter sur ce travail. Leurs remarques m'ont permis d'améliorer le manuscrit et d'enrichir la discussion lors de la soutenance. Je remercie également Christian Barillot et Yves Chiaramella pour avoir accepté de faire partie du jury.

Je voudrais remercier les membres de l'équipe SIC, et en particulier Alain Boucher et Fabrice Bellet pour leur aide tout au long de ma thèse, ainsi que tous les autres étudiants avec qui j'ai pu échanger.

Finalement, je tiens à exprimer toute ma reconnaissance à mes parents qui m'ont permis d'aller jusqu'au bout de ma volonté d'étudier et de me consacrer à un domaine qui me passionne. Je n'oublierai pas non plus le soutien de Pierre-Henry, de Cécile et de Christophe.

Table des matières

Introduction générale	9
1 Présentation générale	13
Introduction	13
1.1 Quelques éléments d'anatomie	13
1.1.1 Le cerveau	13
1.1.2 Les principaux tissus cérébraux	14
1.1.3 Observation du cerveau	16
1.1.4 Acquisition dans le repère de Talairach	16
1.2 Principes physiques élémentaires de l'IRM	17
1.2.1 Champ et moment magnétique	17
1.2.2 Phénomène de résonance	18
1.2.3 Imagerie de résonance magnétique	19
1.2.4 Contraste des images	19
1.2.5 Exemples de séquences	20
1.2.6 Défauts des images	20
1.3 Présentation générale de l'approche	21
1.3.1 Caractéristiques de l'approche	21
1.3.2 Principe de fonctionnement de l'approche	23
Conclusion	24
2 Etat de l'art	27
Introduction	27
2.1 Approches par classification	29
2.1.1 Classification bayésienne	29
2.1.2 Champs de Markov	33
2.2 Approches utilisant des modèles	38
2.2.1 Modèles énergétiques	38
2.2.2 Modèles paramétriques	43
2.2.3 Autres modèles	45

2.3	Approches à base de connaissance	46
2.3.1	Approches proposées	46
2.4	Approches coopératives	51
2.4.1	Coopération séquentielle	51
2.4.2	Coopération itérative	55
	Conclusion	59
3	Modules de base du système	61
	Introduction	61
3.1	Module “Agents”	62
3.1.1	Intérêt et difficultés	62
3.1.2	Nécessité de contraindre	64
3.1.3	Des agents contours et régions	65
3.1.4	Modèle générique d’agent région	67
3.1.5	Modèle générique d’agent A*	68
3.1.6	Architecture du système multi-agents	70
3.2	Module “Modèle”	77
3.2.1	Marquage et alignement des exemples	77
3.2.2	Modélisation statistique	80
3.2.3	Recherche d’un nouvel exemple	83
3.2.4	Aspects de validation	86
3.3	Module “Déecteur de contours”	90
3.3.1	Présentation du déecteur	90
3.3.2	Choix des seuils	92
	Conclusion	96
4	Coopération	97
	Introduction	97
4.1	Coopération par initialisation	100
4.1.1	Isolement du cerveau	101
4.1.2	Localisation des tissus cérébraux	102
4.1.3	Segmentation de la matière grise	104
4.1.4	Segmentation de la matière blanche	113
4.2	Coopération par fusion	119
4.2.1	Sources d’information	120
4.2.2	Choix d’un opérateur de fusion	126
4.2.3	Fonctions de coût	129
4.2.4	Position et nombre des agents A*	132
4.2.5	Heuristiques	132

4.3	Coopération par rétroaction	137
4.3.1	Rétroaction sur la même coupe	138
4.3.2	Rétroaction sur coupe adjacente	139
5	Validation et résultats	145
	Introduction	145
5.1	Construction des images de synthèse	146
5.2	Mesures d'évaluation	148
5.2.1	Cas des régions	148
5.2.2	Cas des contours	151
5.3	Evaluations	153
5.3.1	Protocole d'évaluation	153
5.3.2	Evaluation de la coopération par initialisation	154
5.3.3	Evaluation de la coopération par fusion	159
5.3.4	Evaluation de la coopération par rétroaction	163
5.4	Segmentation d'images réelles	168
	Conclusion	173
	Conclusion générale	175
	Bibliographie	179
	Annexe	187

Introduction générale

L'étude du cerveau humain, que ce soit sur le plan anatomique ou fonctionnel, est actuellement un domaine de recherche en plein essor. Les principaux facteurs qui contribuent à rendre possibles ces études sont principalement l'évolution des matériels et des techniques d'imagerie, la capacité de calcul sans cesse croissante des ordinateurs et enfin la définition et la mise en oeuvre de systèmes complexes de traitement des données.

Face à l'accroissement du nombre d'examens pratiqués en routine clinique, 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.

La mise en oeuvre de tels systèmes est un problème difficile et étudié par de nombreuses équipes de recherche dans le monde entier. Les difficultés se situent à différents niveaux comme par exemple le choix des paramètres d'acquisition des images qui permettront d'obtenir les meilleures données en vue de traitements automatisés, la complexité du cerveau humain dont l'anatomie est extrêmement variable d'un individu à un autre et qui nécessite de mettre en oeuvre des méthodes de traitements très adaptatives, ou encore le type d'information qu'il sera nécessaire de fournir aux systèmes pour permettre leur bon fonctionnement.

Le travail présenté dans cette thèse a pour but la mise en oeuvre d'un système de segmentation d'Images de Résonance Magnétique (IRM) cérébrales qui permette de tirer parti de plusieurs approches complémentaires en réponse à la complexité du problème posé. Plus précisément, l'objectif est de pouvoir intégrer l'approche proposée dans un système plus global dédié au dépliage du cortex cérébral.

Les méthodes de segmentation existantes sont généralement fondées sur des principes très différents comme par exemple les processus de classification, l'utilisation de modèles de contours déformables ou encore de modèles de connaissance. Le but de notre travail est de montrer qu'il est possible de définir un cadre commun de travail pour permettre la mise en oeuvre de coopération entre des approches hétérogènes. L'intérêt d'une telle approche est de pouvoir ex-

exploiter la complémentarité d'informations qui résultent de l'application de plusieurs méthodes afin de proposer un système complet de segmentation.

Le cadre méthodologique que nous avons défini s'articule autour des notions d'apprentissage et d'adaptativité.

L'apprentissage permet d'introduire des connaissances *a priori*, sous forme explicite, sur le contexte de travail. Il est effectué à travers la construction d'un modèle déformable du contour du cerveau qui fournit une information interprétée sémantiquement. Cette information sert à contraindre et spécialiser localement un ensemble d'agents de segmentation, regroupés au sein d'un système multi-agents.

La spécialisation et la distribution des agents contribuent à l'adaptativité du système.

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

La recherche de 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 :

1. *Coopération par initialisation*, qui exploite le résultat d'une méthode pour initialiser une seconde phase de traitements réalisée par une autre méthode.
2. *Coopération par fusion d'informations*, qui permet de tirer parti de la fusion d'informations complémentaires dans le but de guider un processus de segmentation.
3. *Coopération par rétroaction*, qui permet de revenir sur le processus complet de segmentation pour l'affiner ou encore pour transmettre des informations entre différentes images.

Le document est organisé de la façon suivante :

1. Le premier chapitre présente la cadre applicatif qui a servi de support à nos recherches. Il rappelle quelques notions d'anatomie du cerveau humain, les principes fondamentaux de la technique de l'imagerie par résonance magnétique et fournit un plan général de l'approche que nous avons développée.
2. Le second chapitre propose un état de l'art sur la segmentation en IRM cérébrale. Il est organisé en trois parties. Les approches procédant par classification sont d'abord étudiées,

puis les approches utilisant des modèles déformables et les approches utilisant de la coopération sont décrites.

3. Le troisième chapitre présente les différentes méthodes de segmentation qui ont été introduites au sein de modules dans le système. Elles sont au nombre de trois.

Un système multi-agents permet de générer des agents de segmentation spécialisés pour détecter des régions ou des contours.

Un modèle statistique déformable permet d'apprendre la forme du contour du cerveau ainsi que ses modes de déformation, pour ensuite détecter de nouveaux contours du cerveau.

Enfin, un module de détection des contours fondé sur de l'information de type gradient et une représentation spécifique des pixels contours permet de produire des contours de bas-niveau très finement localisés.

4. Le quatrième chapitre décrit l'ensemble des processus de coopération par initialisation, par fusion puis par rétroaction et précise les techniques mises en oeuvre pour réaliser concrètement la segmentation des IRM.

5. Le cinquième chapitre propose une validation de l'ensemble de l'approche à travers l'utilisation d'images simulées développées au Montréal Neurological Institute. Il présente également des résultats obtenus sur des images réelles.

Ce travail a été réalisé dans le cadre d'un programme européen ALLIANCE de collaboration entre le laboratoire TIMC-IMAG (Grenoble) et le Department of Medical Biophysics de l'Université de Manchester (UK). Grâce à l'obtention d'une bourse EURODOC de la région Rhône-Alpes, six mois de travail ont pu être effectués à Manchester, sous la direction du Pr. C. Taylor.

Par ailleurs, nous collaborons avec l'équipe de l'INSERM U438 (Grenoble), dirigé par le Pr. C. Segebarth, dans le contexte d'études en IRM fonctionnelle et d'un projet sur le dépliage du cortex.

Chapitre 1

Présentation générale

Introduction

Cette partie 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 ensuite.

Dans un second temps, nous présentons brièvement les principes physiques de l'imagerie de résonance magnétique en insistant plus particulièrement sur les difficultés qui découlent de cette technique d'acquisition.

Enfin, nous présentons une vue générale de l'approche que nous avons mise en oeuvre pour réaliser la segmentation. Nous décrivons les caractéristiques principales de l'approche ainsi que le principe global de fonctionnement de l'ensemble.

1.1 Quelques éléments d'anatomie

Cerveau : Partie antérieure de l'encéphale des vertébrés formée des hémisphères cérébraux et des structures qui les unissent.

Telle est la définition du cerveau dans le Petit Larousse. Sans se limiter à une description aussi brève, cette partie entend présenter quelques notions générales sur le cerveau qui seront utiles par la suite. Cette partie n'a dans tous les cas aucune intention d'exhaustivité.

1.1.1 Le cerveau

Le système nerveux central est l'organe qui contrôle l'ensemble des comportements de l'individu, qu'il s'agisse de comportements conscients ou inconscients. Il est constitué d'un réseau complexe de communications dont les influx règlent le fonctionnement des organes.

Anatomiquement, le système nerveux central est composé de trois parties : la moelle épinière, le tronc cérébral et le cerveau.

Le cerveau est la partie la plus volumineuse du système nerveux central. Il est constitué essentiellement de deux hémisphères, séparés par la scissure inter-hémisphérique, et reliés 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.

1.1.2 Les principaux tissus cérébraux

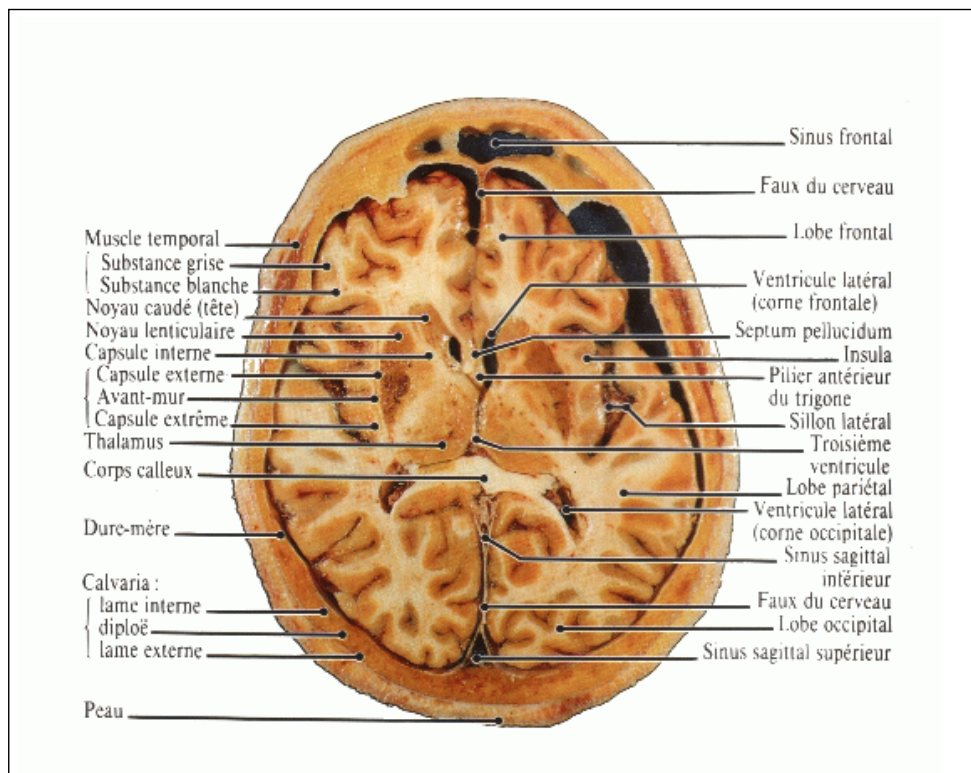


FIG. 1.1: Photographie d'un cerveau post-mortem, visualisation des principaux éléments, d'après [Le Floch 90].

– 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.

– La matière grise :

On peut distinguer plusieurs structures composées de matière grise. D'une part, on trouve le cortex, situé à la périphérie du cerveau et d'autre part les noyaux gris centraux. La matière grise est essentiellement composée de neurones et constitue donc le siège de l'activité cérébrale.

1. 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.

2. Les noyaux gris centraux : Ces noyaux sont également composés de matière grise. Les principaux noyaux sont le noyau caudé, qui longe le ventricule latéral, le noyau lenticulaire composé du putamen et du pallidum et le noyau thalamique qui est le plus gros des noyaux centraux.

– 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 1.1 sur une coupe photographiée post-mortem, et dans la figure 1.2 sur une coupe IRM équivalente (d'après [Le Floch 90]).

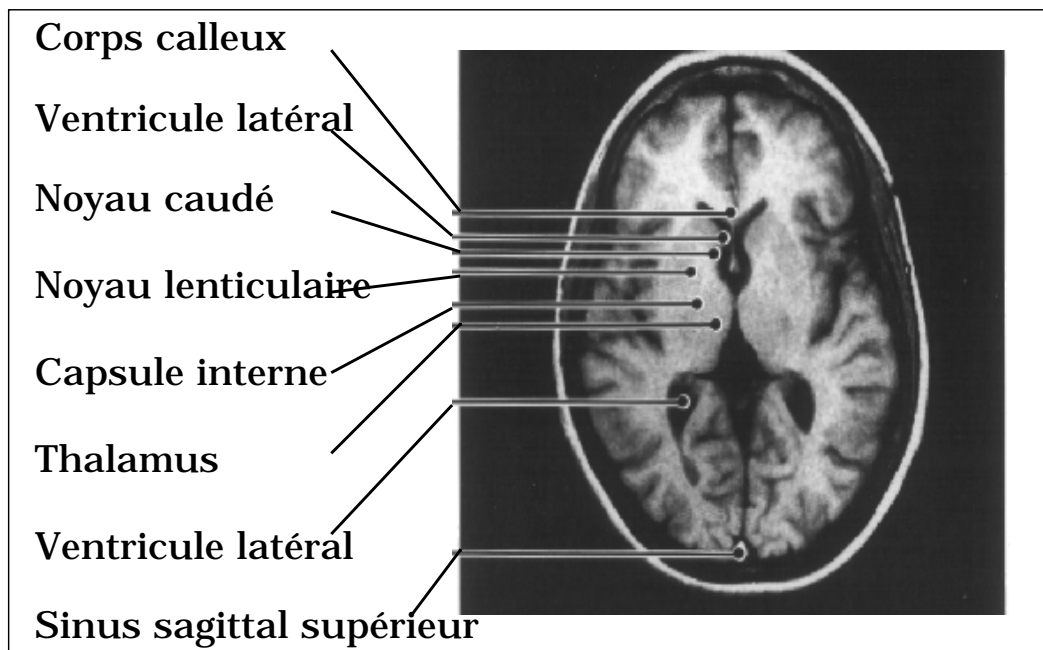


FIG. 1.2: Visualisation des principaux organes dans une coupe IRM, d'après [Le Floch 90] .

1.1.3 Observation du cerveau

L'observation par des coupes en deux dimensions du cerveau peut être effectuée selon plusieurs angles de vue. Ainsi, on distingue trois axes anatomiques pour réaliser les coupes (fig. 1.3).

1. Coupes axiales : Ces coupes correspondent quasiment à un plan horizontal. En imagerie de résonance magnétique, elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.
2. Coupes sagittales : Ces coupes sont prises dans des plans parallèles au plan inter-hémisphérique. Il s'agit de vues latérales du cerveau.
3. Coupes coronales : Ce sont des coupes perpendiculaires aux coupes axiales et sagittales. Elles correspondent à des vues de face du cerveau.

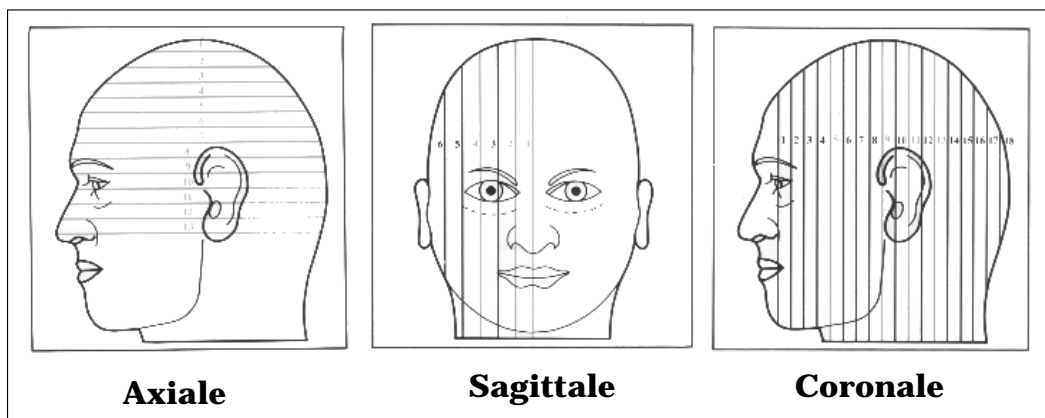


FIG. 1.3: Les trois axes de coupe pour la visualisation du cerveau.

1.1.4 Acquisition dans le repère de Talairach

Les séquences d'images utilisées dans ce travail ont été acquises dans le cadre de recherches sur la vision humaine en IRM fonctionnelle [Roth 96]. Afin d'uniformiser les expériences et de rendre comparables entre elles les images, le repère de Talairach est en général choisi comme référentiel commun.

Le repère de Talairach est fondé sur des repères anatomiques précis et son utilisation permet l'alignement spatial de cerveaux différents par rapport au cerveau de référence de l'atlas de Talairach [Talairach 57], [Talairach 88].

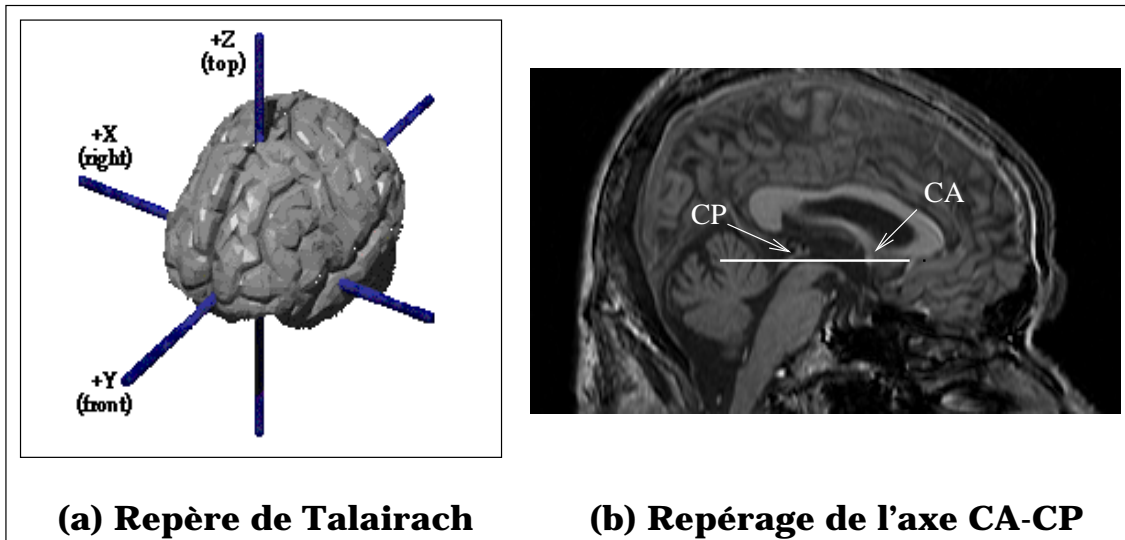


FIG. 1.4: (a) Principe du repère de Talairach. (b) Détection de l'axe CA-CP.

C'est un système de coordonnées direct tel que $+x$ représente la partie droite de l'individu, $+y$ sa partie antérieure et $+z$ sa partie supérieure. Le plan $y-z$ est déterminé par la scissure inter-hémisphérique.

L'axe des y est défini par la ligne CA-CP qui passe sur le contour supérieur de la commissure antérieure (CA) et sous le contour inférieur de la commissure postérieure (CP). L'origine du repère est choisie au point le plus postérieur de CA.

Des procédés de détection automatique de l'axe CA-CP à partir de points de repère anatomiques sont proposés dans [Friston 89] et [Vérard 97]. Une approche de normalisation spatiale est également proposée dans [Lancaster 95].

1.2 Principes physiques élémentaires de l'IRM

Cette section résume les principes élémentaires de l'imagerie par résonance magnétique. Pour plus d'informations on pourra se reporter à [Bittoun 98], [Alaux 94].

1.2.1 Champ et moment magnétique

Le moment magnétique est une grandeur vectorielle caractéristique d'un circuit électrique qui permet d'étudier son comportement dans un champ magnétique. Ainsi, un électron qui décrit une orbite autour d'un noyau constitue une boucle de courant, de moment magnétique $\vec{\mu}$ perpendiculaire à l'orbite.

Lorsqu'un proton est placé dans un champ magnétique \vec{B}_0 statique, son moment magnétique




FIG. 1.5: Mouvement de précession du proton dans un champ magnétique statique.

est animé d'un mouvement de précession (fig 1.5) autour de l'axe de vecteur directeur \vec{B}_0 et sa fréquence de rotation est exprimée par l'équation (1.1) où γ est le rapport gyromagnétique spécifique au noyau étudié.

$$f_0 = \frac{\gamma}{2\pi} B_0 \quad (1.1)$$

Dans le cas du proton, la mécanique quantique n'autorise que deux états possibles de spin $(-1/2, +1/2)$. $\vec{\mu}$ sera donc orienté soit parallèlement à \vec{B}_0 , soit dans la direction opposée à \vec{B}_0 . Comme la population ayant un spin de $1/2$ est très légèrement supérieure à la population ayant un spin de $-1/2$, le moment magnétique résultant \vec{M} sera orienté dans le sens de \vec{B}_0 ; sa composante en z , \vec{M}_z est petite devant \vec{B}_0 . Pour mesurer ce moment magnétique il faut donc le basculer dans le plan transverse XY . Pour cela, on applique une onde radio-fréquence (RF) égale à f_0 et perpendiculaire à \vec{B}_0 .

1.2.2 Phénomène de résonance

En IRM, le signal étudié est l'énergie libérée par l'ensemble des protons lors de leur retour à l'état stable. Le paramètre d'excitation RF joue un rôle essentiel car la composante transverse \vec{M}_{XY} dépend de la durée et de l'amplitude de la RF.

Deux autres paramètres jouent un rôle important lors de l'acquisition d'images : ce sont les constantes de temps décrivant la durée du retour à l'équilibre, le retour étant une fonction exponentielle du temps.

1. T_1 : C'est le temps nécessaire au retour de \vec{M} dans la direction de \vec{B}_0 . Ce temps est appelé temps de relaxation longitudinal ou encore temps de relaxation spin-réseau.
2. T_2 : C'est le temps de relaxation qui décrit le retour à 0 de la composante \vec{M}_{XY} de \vec{M} . Ce temps est appelé temps de relaxation transverse ou temps de relaxation spin-spin.

1.2.3 Imagerie de résonance magnétique

Les phénomènes décrits dans les sections précédentes doivent être appliqués à un grand nombre de noyaux afin d'être décelables. En effet, un noyau seul libère une très faible quantité d'énergie.

Un traitement mathématique fondé sur la transformée de Fourier permet en post-traitement de relier localisation et fréquence pour construire une image en niveaux de gris.

De plus, pour pouvoir associer un signal à chaque pixel d'une image, des gradients de champ sont appliqués qui permettent d'associer des fréquences de résonance différentes à des localisations spatiales distinctes.

1.2.4 Contraste des images

Les images résultant de la mesure de l'aimantation \vec{M} en tout point d'un volume dépendent principalement de trois paramètres intrinsèques :

1. T_1 : Le temps de relaxation longitudinal.
2. T_2 : Le temps de relaxation transverse.
3. ρ : La densité de protons, qui définit la quantité de signal considéré.

Des paramètres extrinsèques liés à la séquence d'acquisition utilisée sont essentiels :

1. TR (temps de répétition) représente le temps qui sépare deux excitations RF successives. Si TR est long ($> 3s$), tous les tissus auront le temps de revenir à leur état initial et le contraste sera quasiment indépendant de T_1 .

Si au contraire, TR est court, on observera des différences de contraste entre les tissus ayant un T_1 court (Pour un champ de 1.5T, 786ms pour la matière blanche) qui pourront revenir à l'équilibre, et les tissus ayant un T_1 long qui ne reviendront pas à l'équilibre (3s pour le liquide cérébro-spinal). Le contraste des images sera donc dépendant des T_1 respectifs des tissus étudiés.

Ce contraste est souvent utilisé pour construire des images anatomiques.

2. TE (temps d'écho) représente le temps qui sépare l'impulsion RF du maximum du signal de résonance magnétique détecté. Ce signal est appelé écho.

Si TE est court ($< 20ms$), la décroissance du signal issue des différents tissus est négligeable et le contraste est quasiment indépendant de T_2 .

Si TE est long ($> 50ms$), le signal sera plus élevé pour les tissus ayant un T_2 plus long.

3. α représente l'angle de basculement de \vec{M} dans le plan XY.

1.2.5 Exemples de séquences

Nous présentons ici quelques séquences qui ont été utilisées pour l'acquisition des images sur lesquelles nous travaillons. FA représente l'angle de basculement en degrés, TR le temps de répétition en ms, TE le temps d'écho en ms, FOV la taille de l'image en mm, Epaisseur l'épaisseur de chaque coupe en mm, Matrix le nombre de pixels obtenus dans les images 2D, OverContiguous indique si les coupes sont acquises directement à l'épaisseur E ou bien à l'épaisseur 2E, et Contrast représente le type de contraste obtenu.

	FA	TR	TE	FOV	Epaisseur	Matrix	OverContiguous	Contrast
séquence 1	30	13	6	220	1	256x256	no	T1
séquence 2	30	8	2	220	1	256x256	no	T1
séquence 3	30	24	6	220	1	256x256	yes	T1
séquence 4	30	13	8	220	2	256x256	no	T1

1.2.6 Défauts des images

Outre les trois paramètres principaux T_1, T_2, ρ 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.

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

– Bruit :

Le bruit a des origines multiples, liées en partie au bruit de l'appareillage. Dans les images de 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 voxels pour multiplier le rapport signal/bruit d'un facteur $\sqrt{8}$, mais la résolution est divisée par deux. Le choix d'acquisition est donc un facteur déterminant.

– Mouvement :

Le mouvement peut provenir de plusieurs sources. Il peut être lié au métabolisme comme la circulation sanguine ou la respiration. 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 .

– Variations du champ magnétique :

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 [Sled 98], [Meyer 95]. Les distortions de champ sont également analysées en détail et corrigées dans [Langlois 99].

– Effets de volume partiel :

Les effets de volume partiel sont directement liés au processus de numérisation du signal. Ainsi, si un voxel 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.

1.3 Présentation générale de l'approche

1.3.1 Caractéristiques de l'approche

Nous présentons dans cette partie les caractéristiques principales de l'approche que nous avons développée pour réaliser la segmentation d'IRM cérébrales. Ces caractéristiques sont l'absence de pré-traitement, l'adaptativité, la coopération et l'aspect 2.5D.

– Pas de pré-traitement :

Dans de nombreuses approches pour la segmentation des étapes de pré-traitement sont nécessaires. Pour les approches fondées sur la classification des tissus en particulier, il

est souvent indispensable d'isoler préalablement le cerveau du reste de l'image si l'on veut éviter de classifier des tissus situés hors du cerveau en tant que tissus cérébraux. Des approches ont été spécifiquement développées afin de fournir un isolement du cerveau à partir d'IRM complètes [Atkins 98], [Lee 98], [Worth 98].

De plus, des techniques de correction des inhomogénéités peuvent être appliquées afin de faciliter la classification [Sled 98], [Meyer 95].

Notre approche n'inclut pas d'étape de pré-traitement. Les images sont directement fournies au système et celui-ci réalise automatiquement l'isolement du cerveau ainsi que l'adaptativité aux inhomogénéités. La phase d'isolement du cerveau est incluse dans l'approche grâce à l'utilisation d'un modèle statistique déformable du contour du cerveau.

– Adaptativité :

L'approche que nous proposons prend directement en compte l'existence d'inhomogénéités dans les images. Cela est possible grâce à l'utilisation d'un ensemble d'agents de segmentation par régions dans lequel chaque agent est spécialisé localement à partir de l'analyse d'échantillons de tissus.

L'intérêt d'un tel principe de spécialisation est qu'il n'y a aucun *a priori* sur les niveaux de gris des tissus à segmenter. L'approche s'adapte ainsi automatiquement à des séquences variées d'acquisition.

– Coopération :

Une caractéristique importante de notre approche est l'intégration au sein d'un même système d'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.

Nous avons intégré trois grands modules dans le système qui sont :

1. Un système multi-agents.
2. Un modèle statistique déformable.
3. Un détecteur de contours.

Les modules interagissent dans un cadre coopératif qui peut être caractérisé plus précisément selon le type de coopération mis en oeuvre :

1. La coopération par initialisation consiste à exploiter le résultat d'une approche pour initialiser une seconde approche.
2. La coopération par fusion consiste à fusionner plusieurs informations pour réaliser une étape de la segmentation.

3. La coopération par rétroaction permet un retour sur des étapes antérieures dans un but d'amélioration de la solution ou de transmission du résultat obtenu à d'autres images.

– Aspect 2.5D :

L'approche a été développée dans le cadre de la segmentation de coupes 2D essentiellement parce qu'un modèle déformable 3D n'est pas encore disponible. Nous sommes conscients qu'une telle dimensionnalité peut être un facteur limitant dans ce type d'application.

Cependant, nous tirons parti de notre processus de coopération par rétroaction pour générer une segmentation 2.5D grâce à un principe de transmission de l'information entre coupes adjacentes.

1.3.2 Principe de fonctionnement de l'approche

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

– 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.

– 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 :

1. Segmentation de la matière grise.

2. Segmentation de la matière blanche.

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. La 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.

– Détection des contours :

A l'issue de la segmentation en régions, nous utilisons des agents contours spécifiques pour reconstruire un contour du cerveau plus précis que celui fourni par le modèle. 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.

– Rétroaction :

Dans un troisième cadre coopératif, celui de la coopération par rétroaction, nous envisageons un retour sur le processus complet de segmentation en considérant le contour reconstruit par les agents contours comme remplaçant du modèle déformable. Le nombre de boucles de rétroaction nécessaires est discuté dans le chapitre 5.

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 1.6 illustre l'ensemble des étapes de notre approche pour la segmentation.

Conclusion

Nous avons présenté dans cette partie les notions essentielles liées à l'anatomie du cerveau ainsi que les principes d'acquisition des images de résonance magnétique.

Ensuite, nous avons décrit les caractéristiques de notre approche et son principe de fonctionnement.

Dans la suite de ce document, nous étudions l'état de l'art dans le domaine de la segmentation, puis nous détaillons les différents aspects de notre approche.

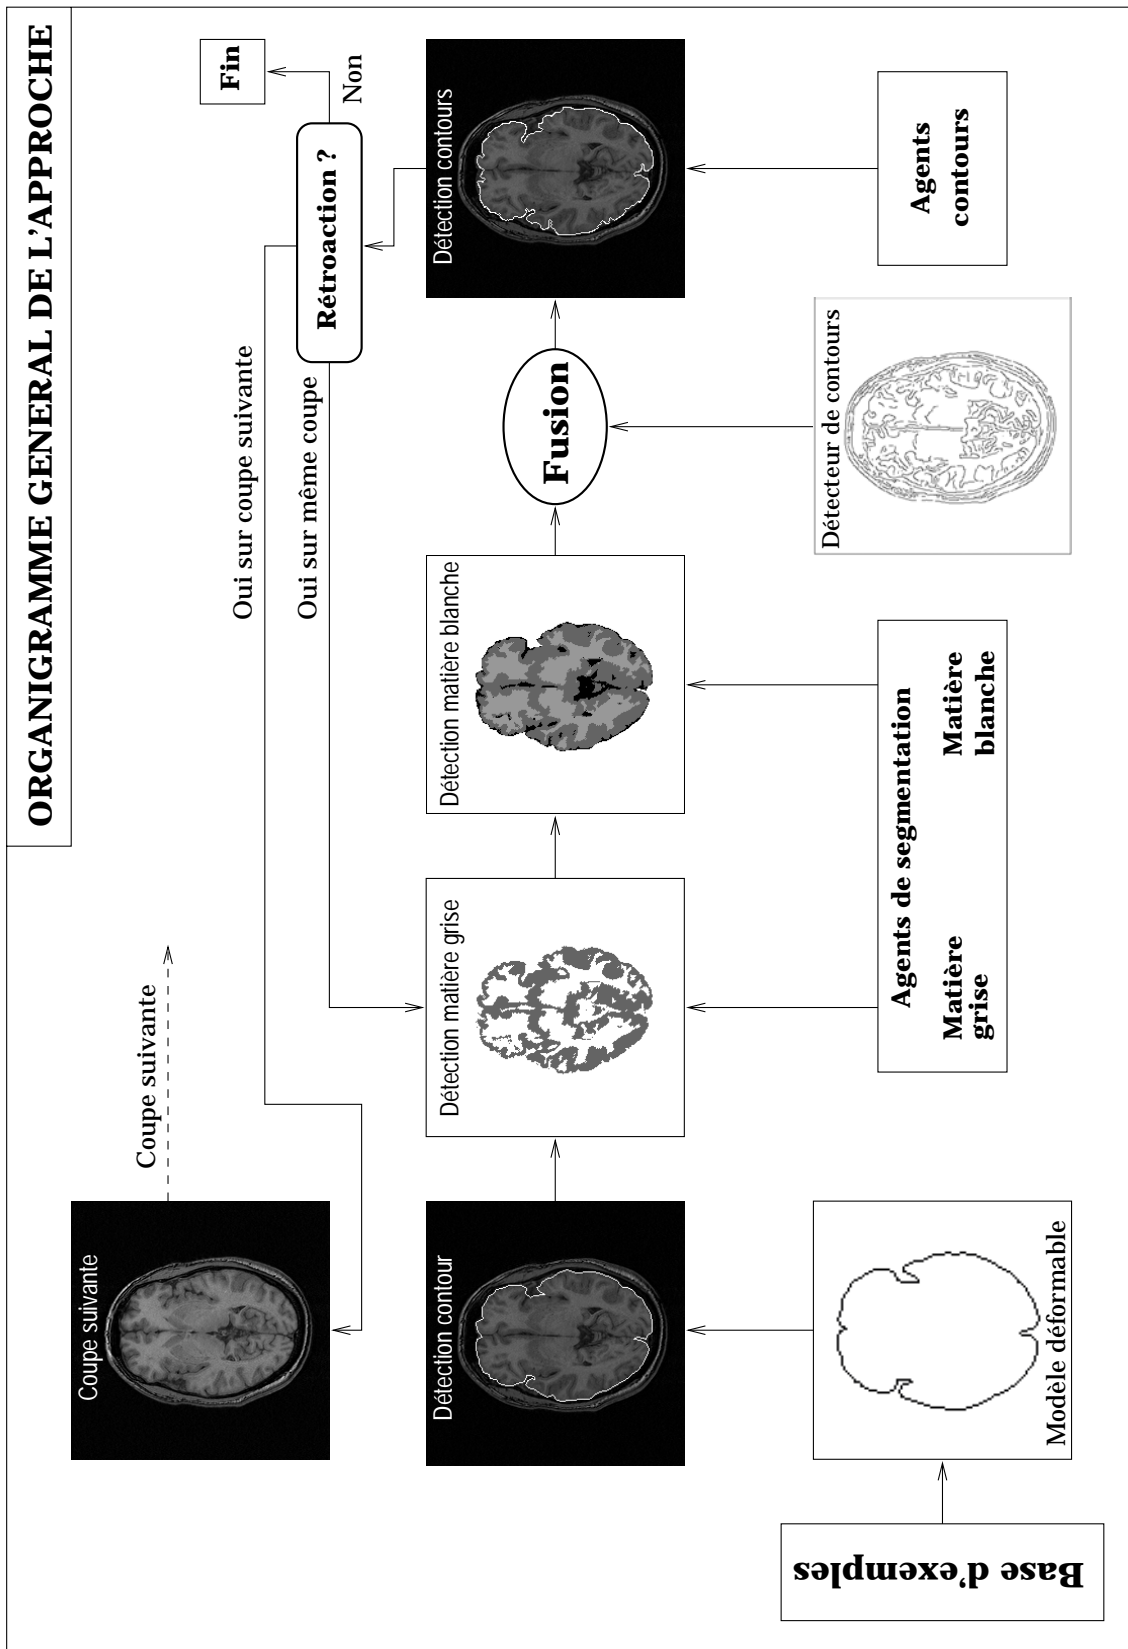


FIG. 1.6: Principe général de la segmentation réalisée par l'approche proposée.

Chapitre 2

Etat de l'art

Introduction générale

Dans le cadre de nos recherches sur la segmentation coopérative, nous avons été amenés à étudier un large éventail d'approches. Afin de mieux comprendre l'intérêt et la spécificité des différents axes étudiés nous avons cherché à effectuer une caractérisation des approches selon des critères relativement généraux. Comme toute classification, nous sommes conscients qu'elle admet des limites, cependant, dans le cadre de nos recherches en IRM cérébrale, il nous semble qu'elle est adaptée au problème étudié et aide à une meilleure compréhension. De plus, des classifications ont été proposées dans [Clarke 95] [Bezdek 93] qui sont cohérentes avec la nôtre.

Ainsi, nous avons distingué deux axes caractéristiques : i) l'existence et le caractère local ou global d'une modélisation, ii) la nature des connaissances *a priori*, implicite ou explicite.

L'aspect de modélisation est plutôt associé à l'existence de modèles mathématiques ou statistiques des données au sein des systèmes de segmentation. Ces modèles peuvent être globaux, c'est-à-dire utilisés indifféremment dans toutes les parties d'une image ou bien locaux et utilisés pour contraindre localement des processus de classification. La connaissance *a priori* utilisée pour guider les processus de segmentation peut être introduite directement dans les systèmes, ou bien représentée sous des formes plus explicites.

Ces deux axes nous ont permis de caractériser l'ensemble des méthodes étudiées et de les regrouper selon ces caractéristiques. Graphiquement, notre caractérisation aboutit à un tableau à double entrée (modélisation/connaissance *a priori*) dans lequel nous avons positionné chaque grand type d'approche en segmentation (voir fig. 2.1).

Selon cette classification, notre approche se situe en bas à droite du tableau, avec la particularité d'inclure à la fois des modèles locaux et globaux, ainsi que de la connaissance *a priori*, dans un cadre coopératif.

APPROCHES POUR LA SEGMENTATION			
	SANS	LOCALE	GLOBALE
MODELISATION CONNAISSANCE A PRIORI	APPROCHES BAS-NIVEAU Brummer(91)	CLASSIFICATION Wells(96) Jaggi(98) Rajapakse(97)	MODELES ENERGETIQUES Chiou(95) Davatzikos(95)
	APPROCHES A BASE DE CONNAISSANCE Gong(95) Li(95) Dellepiane(91) Sonka(96)	CLASSIFICATION Friston(95) Mangin(95)	MODELES PARAMETRIQUES ----- Cootes(95) Collins(95) Szekely(96) Duta(98)
IMPLICITE			COOPERATION Kapur(96) Teo(97) Warfield(96) Bozma(92) Chakraborty(99) Germond(99)
EXPLICITE			

FIG. 2.1: Classification proposée pour les approches de segmentation en IRM cérébrale selon deux axes principaux (modélisation/connaissance *a priori*).

Outre les aspects de modélisation ou d'intégration de connaissance *a priori*, les méthodes développées pour la segmentation peuvent être envisagées sous l'angle des objectifs recherchés. En effet, le problème de la segmentation peut être décomposé en plusieurs sous-problèmes, essentiellement la détection des tissus cérébraux et la recherche des contours des organes étudiés.

Ainsi, la segmentation en régions sera plutôt associée à des méthodes de classification et la détection des contours sera plutôt associée à des modèles déformables. Des approches dites "coopératives" ont été développées dans le but de combiner plusieurs objectifs au sein de systèmes complets, en réponse aux difficultés soulevées par l'utilisation d'approches comme la modélisation ou la classification.

Dans ce chapitre, nous portons plus spécifiquement notre étude sur les approches par classification, les approches utilisant des modèles énergétiques ou paramétriques, les approches à base de connaissance et les approches coopératives.

Les approches de type bas-niveau [Brumer 91], plus anciennes, ont montré leurs limites dans le cadre de problèmes complexes et nous ne les détaillerons pas.

2.1 Approches par classification

Les approches par classification sont largement utilisées pour la segmentation en IRM cérébrale [Laidlaw 98] [Friston 95] [Wells 96]. Dans cette partie nous présentons les éléments théoriques de la classification bayésienne et des champs de Markov. Nous montrons ensuite comment ces théories ont été utilisées et enrichies pour répondre au problème de la segmentation en IRM cérébrale.

2.1.1 Classification bayésienne

La classification bayésienne consiste à segmenter une image par le calcul de probabilités d'appartenance à un tissu donné pour chaque pixel de l'image. Cette approche utilise la règle de Bayes combinée à des modèles généraux décrivant les distributions des niveaux de gris des tissus recherchés.

2.1.1.1 Eléments théoriques

E	Espace des caractéristiques
Ω	Ensemble des classes
c	Nombre de classes
X	Ensemble des individus à classifier
n	Nombre d'individus à classifier

L'objectif de ce type d'approches est de calculer, pour chaque individu d'une population, sa probabilité d'appartenir à une classe donnée. Le principe est fondé sur les probabilités conditionnelles ainsi que le théorème de Bayes. La probabilité d'avoir une classe ω_i connaissant un individu x est exprimée par l'équation (2.1) :

$$p(\omega_i|x) = \frac{p(x|\omega_i)p(\omega_i)}{p(x)} \quad (2.1)$$

La fonction de décision bayésienne c consiste à associer à chaque individu la classe à laquelle il appartient avec la probabilité la plus forte. C'est la règle du maximum *a posteriori* (MAP) qui s'écrit :

$$c : \begin{cases} E \longrightarrow \Omega \\ x \longmapsto \omega_i \quad , \quad p(\omega_i|x) \geq p(\omega_j|x) \forall j = 1..c \end{cases} \quad (2.2)$$

En pratique, les méthodes utilisant la classification bayésienne se fondent sur une représentation paramétrique de la densité de probabilité $p(x|\omega_i)$ d'un pixel d'appartenir à une classe donnée. La paramétrisation la plus répandue est effectuée à l'aide de fonctions gaussiennes.

2.1.1.2 Approches proposées

Les approches que nous décrivons ci-dessous sont représentatives des méthodes utilisées en classification bayésienne. Nous avons choisi de les présenter car elles apportent des éléments supplémentaires intéressants par rapport à l'approche théorique. En effet, Friston propose un moyen d'introduire de la connaissance *a priori* dans le processus de segmentation et Wells introduit un modèle de bruit pour tenir compte des inhomogénéités.

➤ Friston & al.

[Friston 95] exploitent le principe de la classification bayésienne pour segmenter des images 3D du cerveau en 4 classes (matière grise, matière blanche, liquide céphalo-rachidien et autres). L'originalité de l'approche réside dans l'introduction de connaissance *a priori* pour initialiser les cartes de probabilité. La connaissance *a priori* est constituée par un

atlas probabiliste représentant la probabilité moyenne pour un pixel d'appartenir à une classe donnée. Ces cartes ont été établies à partir d'un grand nombre d'images segmentées fournies par le Montreal Neurological Institute [Evans 93].

L'algorithme est itératif et fondé sur le calcul des paramètres des fonctions gaussiennes représentant les distributions :

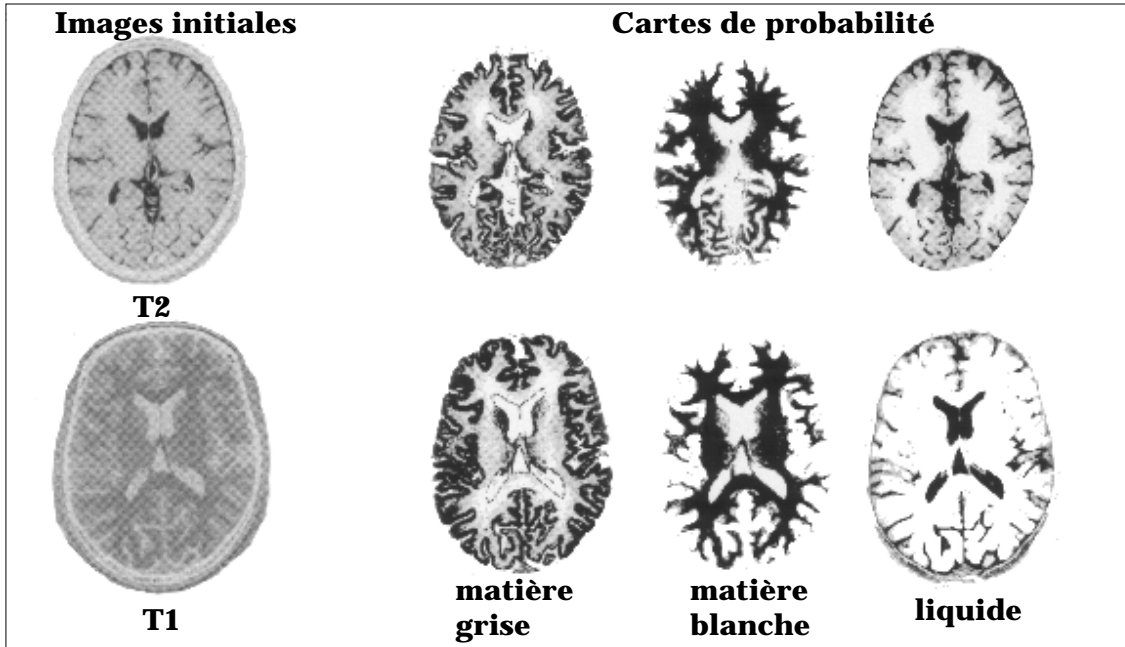


FIG. 2.2: Segmentation probabiliste en 3 classes de 2 types de séquences d'acquisition.

1. Initialiser la probabilité p_{ik} d'appartenance d'un pixel i à un tissu k grâce à l'atlas probabiliste, pour tout pixel de l'image. (Cela nécessite la normalisation de l'image étudiée dans le repère de l'atlas).
2. Calculer la moyenne pondérée de l'intensité de chaque tissu v_k . L'intensité au pixel i étant $f(x_i)$.

$$v_k = \frac{\sum_{i=1}^I p_{ik} f(x_i)}{\sum_{i=1}^I p_{ik}} \quad (2.3)$$

3. Calculer la variance pondérée de l'intensité de chaque tissu c_k :

$$c_k = \frac{\sum_{i=1}^I p_{ik} (f(x_i) - v_k)^2}{\sum_{i=1}^I p_{ik}} \quad (2.4)$$

4. Ré-estimer les probabilités d'appartenance grâce à l'estimation courante des distributions gaussiennes de paramètres (v_k, c_k)

$$r_{ik} = (2\pi c_k)^{-0.5} \exp\left(\frac{-(f(x_i) - v_k)^2}{2c_k}\right) \quad k = 1..4, i = 1..I \quad (2.5)$$

5. Intégrer la probabilité *a priori* p_{ik} d'avoir le tissu k au pixel i dans le calcul des probabilités d'appartenance et normaliser la somme des probabilités pour chaque pixel :

$$p_{ik} \leftarrow \frac{r_{ik} p_{ik}}{\sum_{j=1}^4 r_{ij} p_{ij}} \quad (2.6)$$

L'algorithme est répété jusqu'à convergence. En général 2 à 3 itérations suffisent.

Une limite importante de cette approche est qu'elle est fondée sur une hypothèse d'uniformité des niveaux de gris pour un même tissu dans toutes les zones de l'image, hypothèse non vérifiée dans la réalité. Par conséquent, des erreurs de classification peuvent résulter du traitement choisi.

En contrepartie, l'introduction de connaissance *a priori* sous forme de probabilité permet de simplifier les calculs pour la classification et d'éviter le recours à un processus d'isolement du cerveau par rapport au reste de l'image.

➤ Wells & al.

[Wells 96] proposent une approche par classification bayésienne pour segmenter de façon adaptative les images du cerveau. L'objectif est d'intégrer dans le processus de classification une estimation du biais qui reflète les inhomogénéités présentes dans les images IRM.

Le principe est d'estimer le biais par un bruit blanc gaussien additif pour mieux classifier. On note x l'image à segmenter, η le bruit et ω la classification. L'intensité d'un pixel i est représentée par la somme de la moyenne des intensités pour la classe k et du bruit :

$$x_i = \mu_{ki} + \eta_{ki} \quad \text{et} \quad \eta_{ki} \approx N(0, \sigma_{ki}^2) \quad (2.7)$$

L'objectif est d'estimer le biais η grâce à sa modélisation par une fonction gaussienne et l'application de la règle de Bayes (la quantité $p(x)$ est indépendante de la segmentation) :

$$p(\eta|x) = \frac{p(x|\eta)p(\eta)}{p(x)} \quad (2.8)$$

Le meilleur estimateur du biais est le suivant :

$$\hat{\eta} = \operatorname{argmax}_{\eta} p(\eta|x) \quad (2.9)$$

Il est obtenu en différenciant l'équation (2.9) par rapport à η et en recherchant la nullité des dérivées partielles. Les calculs sont effectués en remplaçant $p(\eta|x)$ par sa modélisation gaussienne et en utilisant la règle de Bayes.

La recherche d'un estimateur maximal *a posteriori* de η est effectuée itérativement grâce à l'algorithme d'Estimation/Maximisation (E/M). L'interprétation des deux étapes est la suivante : l'étape E correspond à l'estimation des probabilités *a posteriori* sur les classes lorsque le biais est connu ; l'étape M consiste à trouver une estimation par maximum *a posteriori* (MAP) du biais lorsque les probabilités des tissus sont connues.

► Bilan sur les approches bayésiennes

Les approches présentées ci-dessus font apparaître deux tendances actuelles fortes en segmentation. La première est l'introduction de connaissance *a priori* au sein d'un processus de segmentation. Cela permet de mieux contraindre un problème tout en tirant parti de résultats acquis antérieurement. L'utilisation de connaissance apparaît comme un facteur de progression vers une résolution plus fiable du problème étudié. La seconde est la prise en compte des inhomogénéités dans le processus de segmentation. Cette approche montre que l'utilisation de modèles globaux est insuffisante et qu'il est nécessaire de travailler à un niveau plus local en particulier grâce à des modèles d'inhomogénéité.

2.1.2 Champs de Markov

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 [Rajapakse 97] [Held 97] [Jaggi 98] [Géraud 98]. 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.

2.1.2.1 Éléments théoriques

Les approches utilisant les champs de Markov sont fondées sur une théorie utilisant des notions de voisinages et de cliques que nous rappelons ici [Cocquerez 95].

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

$$I = \{p_{ij} = (i, j), 1 \leq i, j \leq N\}$$

A chaque pixel est associée une variable aléatoire A_i 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 :

1. Un pixel n'appartient pas à son voisinage
2. La relation de voisinage est symétrique : si un pixel s appartient au voisinage v_t 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) :

$$\begin{cases} P(a) > 0 \\ P(a_i | a_j, j \in I - \{i\}) = P(a_i | a_j, j \in v_i) \end{cases} \quad (2.10)$$

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 [Besag 74] 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 :

$$\forall A \in \Omega^{N \times N}, P(a) = \frac{\exp(-U(a))}{\sum_{a \in \Omega^{N \times N}} \exp(-U(a))} \quad (2.11)$$

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

Application à la segmentation

Dans le cadre de l'approche markovienne la segmentation est considérée comme l'estimation d'une image classifiée Λ à partir de l'image observée A, c'est-à-dire la modélisation de $P(\Lambda = \lambda | A = a)$ [Geman 84]. L'approche classique consiste à utiliser une approche bayésienne qui permet, à partir d'une modélisation *a priori* de la loi sur Λ de retrouver la probabilité $P(\Lambda = \lambda | A = a)$.

En général, Λ est une loi paramétrée et les paramètres optimaux sont obtenus par maximisation *a posteriori* de la probabilité, ce qui est équivalent à une minimisation de l'énergie $U(\lambda|a)$. Le calcul de λ est effectué par des algorithmes de type Iterated Conditional Modes (ICM) ou de recuit stochastique simulé.

Ainsi, l'approche markovienne de la segmentation consiste à définir une énergie sur une image puis à trouver une classification qui minimise cette énergie. Ce type d'approche est à mettre en relation avec les approches de type contours actifs qui utilisent aussi des principes de minimisation énergétique pour la recherche de contours.

2.1.2.2 Approches proposées

Les approches présentées ci-dessous montrent comment la théorie des champs de Markov peut être utilisée en IRM cérébrale. Dans l'approche de Rajapakse [Rajapakse 97], la modélisation des inhomogénéités par un bruit blanc gaussien additif permet d'introduire directement la prise en compte du bruit dans le processus de segmentation. L'approche proposée par Jaggi [Jaggi 98] permet de répondre à un autre problème de l'IRM lié aux effets de volumes partiels et l'approche de Mangin [Mangin 95] propose un principe d'introduction de connaissance de haut-niveau pour guider des processus de bas-niveau.

➤ Rajapakse & al.

[Rajapakse 97] propose d'appliquer la classification par champs de Markov à des images où le cerveau a été préalablement isolé du reste de l'image. L'approche consiste à classer les 3 classes restant après isolement du cerveau (matière grise, matière blanche et liquide céphalo-rachidien).

Les deux hypothèses principales sont :

1. Les intensités peuvent être modélisées par des distributions gaussiennes.
2. L'image est entachée d'erreurs locales (biais) qui peuvent être modélisées par un bruit blanc additif gaussien.

L'objectif est de résoudre $p(\omega|x)$, ce qui d'après la formule de Bayes, en considérant la quantité $p(x)$ indépendante de la segmentation, revient à estimer la quantité $p(x|\omega)$:

$$p(\omega|x) \approx p(x|\omega)p(\omega) \quad (2.12)$$

Les intensités des pixels sont représentées par l'équation (2.13) :

$$x_i = \mu_{ki} + \eta_{ki} \quad (2.13)$$

où μ_{ki} représente la moyenne de la classe k au pixel i et η_{ki} représente le bruit au même point. La modélisation du bruit est la suivante et permet de déduire une modélisation pour les intensités (2.14) :

$$\eta_{ki} = N(0, \sigma_{ki}^2) \Rightarrow x_i = N(\mu_{ik}, \sigma_{ki}^2) \quad (2.14)$$

L'ensemble d'équations suivantes montre comment la modélisation locale des intensités permet de mettre la recherche de la probabilité $p(x|\omega)$ sous forme d'une fonction d'énergie et ainsi de transformer le problème en une minimisation de fonctionnelle énergétique.

$$\begin{aligned} p(x|\omega) &= \prod_k \prod_{i \in k} p_k(x_i | \mu_{ki}, \sigma_{ki}^2) \\ &= \prod_k \prod_{i \in k} \frac{1}{\sqrt{2\pi}\sigma_{ki}} \exp\left(-0.5 \left(\frac{x_i - \mu_{ki}}{\sigma_{ki}}\right)^2\right) \\ &= \frac{1}{(2\pi)^{|I|/2}} \exp\left(-\sum_k \sum_{i \in k} 0.5 \left(\frac{x_i - \mu_{ki}}{\sigma_{ki}}\right)^2 - \sum_k \sum_{i \in k} (\log(\sigma_{ki}))\right) \end{aligned} \quad (2.15)$$

En ajoutant au terme sous la fonction exponentielle un terme décrivant le potentiel des cliques de l'image :

$$V_{C_i} = \sum_{i,j \in C_i} (-\beta_l \delta(x_i = x_j) + \beta_l \delta(x_i \neq x_j)) \quad (2.16)$$

où β_l est une constante réelle positive, on obtient l'expression d'une fonction d'énergie $U(x)$. La recherche de l'estimateur de maximum *a posteriori* de la segmentation est alors équivalente à la minimisation de U . L'optimisation est effectuée itérativement en 2 étapes :

1. Trouver la segmentation optimale, lorsque les coefficients décrivant le biais sont fixés.
2. Trouver les paramètres décrivant le bruit et le potentiel des cliques (μ, σ, β) optimaux lorsque la segmentation est fixée.

La procédure Iterated Conditional Modes (ICM) est utilisée pour réaliser l'optimisation.

➤ Jaggi

[Jaggi 98] propose une approche par champs de Markov permettant de prendre en compte les effets de volume partiels. Le principe est d'effectuer une classification par champs de Markov en 2 étapes. La première étape permet une classification en 5 classes (matière grise, matière blanche, liquide céphalo-rachidien, mixtures de gris et blanc et mixtures de gris et liquide). Cette première classification en 5 classes permet de ré-effectuer une classification plus robuste des 3 classes recherchées (matière grise, matière blanche et liquide céphalo-rachidien). A l'issue de la deuxième étape, il est possible d'affecter définitivement

les pixels initialement considérés comme mixtures dans une classe de base. Cette approche progressive permet de prendre en compte un problème spécifique de l'IRM cérébrale dans le cadre d'une théorie bien établie.




FIG. 2.3: Segmentation par classification des tissus en 5 classes pour la prise en compte des effets de volume partiel, d'après [Jaggi 98].

➤ Mangin

[Mangin 95] propose d'introduire de la connaissance *a priori* locale dans le processus de segmentation. Ainsi, des modèles locaux des propriétés topologiques du résultat recherché sont utilisés pour guider un processus de minimisation énergétique où le minimum correspond à la segmentation recherchée. Les contraintes topologiques permettent en outre de distinguer des objets dont les intensités sont similaires.

L'intérêt de cette approche est de proposer un cadre de travail dans lequel il est possible de guider les processus de bas-niveau directement par des modèles de connaissance de haut-niveau.

► Bilan sur les approches markoviennes

L'utilisation de processus d'optimisation stochastiques permet d'obtenir des classifications correspondant à des minima globaux d'énergie. Etant donné le type d'images étudiées, il apparaît donc que des processus peu déterministes soient plus adaptés pour la segmentation que des processus plus rigides utilisant des modèles des distributions.

L'adaptativité est également un facteur important intervenant dans la qualité des résultats de segmentation que les approches par classification peuvent produire.

Cependant, l'adaptativité ne peut être mise en valeur que si elle est bien encadrée par des apports de connaissances du domaine. Nous verrons dans le chapitre 4 comment cette caractéristique très souhaitable d'adaptativité peut être introduite dans le système que nous proposons.

Les approches procédant par classification permettent d'obtenir efficacement et rapidement, en 2D comme en 3D, des résultats de segmentation. Cependant, les connaissances qui permettent de guider ces processus restent dans la majorité des cas peu explicites en comparaison avec les approches utilisant des modèles.

2.2 Approches utilisant des modèles

Excepté pour les modèles structurels et les atlas, les approches utilisant des modèles, qu'ils soient énergétiques ou paramétriques, sont majoritairement utilisées pour rechercher des contours. Dans le cadre de l'IRM cérébrale la recherche de contours est un problème difficile dû au grand nombre d'organes présents et à la complexité de leur structure. L'utilisation d'opérateurs de bas-niveau de type détecteur de gradient ne permet pas de fournir des informations suffisamment structurées. En réponse à cette difficulté, de nombreux modèles ont été proposés. Une revue complète est présentée dans [Mc Inerney 96]. Leur caractéristique principale est une conservation de la topologie de l'objet recherché et leur force majeure est leur capacité de déformation. Nous étudions principalement 2 types de modèles dans cette partie : les modèles de type énergétique et les modèles de type paramétrique.

2.2.1 Modèles énergétiques

Les modèles énergétiques concernent essentiellement les contours dits "actifs" ou "snakes". Le principe est de représenter un contour par une courbe paramétrique et de le soumettre à des forces pour le déformer. La difficulté majeure liée à ce type d'approche est la définition d'une "bonne" fonction d'énergie. En effet, la fonction d'énergie, une fois déterminée, permet de déduire la solution. (Cela revient, étant donné l'aspect global de la fonction d'énergie, à rechercher une solution globale pour l'image.) Une autre difficulté essentielle est liée à l'initialisation des contours actifs.

2.2.1.1 Eléments théorique sur les contours actifs

Les contours actifs, ou "snakes" sont représentés par une courbe paramétrique dont la déformation est contrôlée par une fonctionnelle énergétique [Kass 88] [Cohen 93].

Approche statique :

Dans le cas de l'approche statique, la courbe est représentée par l'équation suivante :

$$C = \{v(s) = (x(s), y(s)); s \in [0, 1]\} \quad (2.17)$$

et associée à une fonction d'énergie $E(v(s))$ telle que E soit minimale lorsque C est positionnée sur le contour recherché.

Expression de l'énergie :

La courbe déformable est soumise à 2 types de forces, des forces internes contrôlant la rigidité et la tension du contour, représentées par les fonctions w_1 et w_2 , et des forces externes décrivant l'attraction du contour vers les contours de l'image, représentées classiquement par un gradient P (2.18).

$$P(v) = -\|\nabla I(v(s))\|^2 \quad (2.18)$$

$$E(C) = E_{interne}(C) + E_{image}(C) \quad (2.19)$$

$$E_{image}(C) = \int_0^1 w_1(s) \left| \frac{\partial v}{\partial s} \right|^2 + \int_0^1 w_2(s) \left| \frac{\partial^2 v}{\partial s^2} \right|^2 + \int_0^1 P(v(s)) ds \quad (2.20)$$

Minimisation de l'énergie

La courbe $v(s)$ qui minimise E doit vérifier l'équation d'Euler-Lagrange

$$-\frac{\partial}{\partial s} \left(w_1 \frac{\partial v}{\partial s} \right) + \frac{\partial^2}{\partial s^2} \left(w_2 \frac{\partial^2 v}{\partial s^2} \right) + \nabla P(v(s)) = 0 \quad (2.21)$$

Cette équation peut être linéarisée en appliquant une méthode de différences finies.

$$Ku = F \quad (2.22)$$

où u est le vecteur des $v_i = v(ih)$ (contour discrétisé), F le vecteur des $F(v_i)$ et K une matrice pentadiagonale. La résolution du système se fait par calcul matriciel (décomposition LU de K).

Approche dynamique

La minimisation énergétique peut aussi être vue comme un problème de recherche d'équilibre. Les équations de Lagrange permettent de formaliser cette approche. Le contour est associé à une masse $\mu(s)$ et à une densité d'amortissement $\gamma(s)$; le facteur de temps t intervient dans cette formulation :

$$\mu \frac{\partial^2 v}{\partial t^2} + \gamma \frac{\partial v}{\partial t} - \frac{\partial}{\partial s} \left(w_1 \frac{\partial v}{\partial s} \right) + \frac{\partial^2}{\partial s^2} \left(w_2 \frac{\partial^2 v}{\partial s^2} \right) = - \nabla P(v(s, t)) \quad (2.23)$$

La discrétisation de cette équation est formulée par :

$$M\ddot{u} + C\dot{u} + Ku = F \quad (2.24)$$

Puis l'équation est linéarisée par différences finies et résolue par des méthodes numériques.

2.2.1.2 Approches proposées

Les principales difficultés inhérentes à l'utilisation de contours actifs pour détecter des contours dans les IRM sont le choix d'une position initiale pour ces contours et d'une fonction d'énergie pour en guider les déformations. Eventuellement, le problème des modifications topologiques peut être envisagé, une approche en ce sens a été proposée par Mc Inerney & Terzopoulos dans [Mc Inerney 95] et par Caselles dans [Caselles 92].

Nous présentons ci-dessous deux approches intéressantes du point de vue de l'initialisation du contour, puis une approche décrivant une fonction d'énergie spécifique pour la détection des replis du cortex.

➤ Chiou & Hwang

[Chiou 95] proposent une approche utilisant un apprentissage par réseau de neurones pour définir une connaissance spécifique. Cette connaissance permet l'établissement d'une fonction d'énergie spécifique exploitée pour mieux guider la déformation de contours actifs. L'approche est appliquée à la recherche du contour du cerveau.

1. Extraction de la connaissance pour l'énergie externe. Le réseau de neurone est entraîné avec 2 classes de pixels : des pixels appartenant au contour du cerveau et des pixels n'y appartenant pas. Pour chaque pixel sélectionné manuellement, une fenêtre de taille 9x9, composée de pixels en niveaux de gris, est présentée au réseau qui doit faire la classification. Le réseau fournit une valeur d'évaluation de la classification entre 0 et 1.

2. Fonction d'énergie externe : pour une image donnée, chaque pixel est associé à sa probabilité d'appartenir au contour. Les probabilités sont binarisées et couplées à une carte de gradient par un opérateur AND. Le résultat est lissé par un noyau gaussien et utilisé comme fonction d'énergie externe.
3. Le contour actif est associé à une force de pression interne, ce qui permet de l'initialiser par une courbe fermée située au centre du cerveau, le centre étant localisé automatiquement.

➤ Kapur & al.¹

[Kapur 96] proposent un algorithme de détection du cerveau en 3 étapes pour améliorer l'initialisation du contour et la détermination de l'énergie liée à l'image. Les 2 premières étapes consistent en une classification des tissus par un algorithme E/M et une phase d'érosion/dilatation pour isoler le cerveau des autres composants de la tête.

La troisième étape a pour objectif de parfaire l'isolement du cerveau quand la seconde étape est insuffisante. Des snakes sont utilisés à cet effet. L'originalité de leur utilisation réside dans la définition de l'énergie externe. Cette énergie est en effet basée sur le résultat des étapes 1 et 2. La procédure associe un signe positif (attraction) aux pixels étiquetés cerveau et un signe négatif (répulsion) aux autres pixels.

L'énergie est ainsi adaptée au contour recherché et ne dépend pas uniquement de l'image initiale à segmenter. Dans cette approche, le contour reste initialisé manuellement sur quelques coupes, puis le résultat est propagé de coupe en coupe pour segmenter le reste de la surface du cerveau en 3D.

➤ Davatzikos & Prince

[Davatzikos 95] proposent un modèle de contour actif spécifique à la segmentation du cortex. L'énergie interne est limitée à l'utilisation de forces élastiques afin de permettre au contour de suivre les convolutions des sillons corticaux. En effet, une contrainte de rigidité empêche les convolutions fortes lors d'une minimisation énergétique.

Le modèle représente le cortex comme un ruban d'épaisseur constante et le contour actif comme le squelette de ce ruban. La force externe appliquée au ruban est fonction de la probabilité de chaque pixel d'appartenir à la matière grise. Les probabilités sont calculées à partir d'une modélisation des distributions des niveaux de gris de chaque tissu. Ainsi, le ruban est attiré vers les points de plus forte probabilité d'appartenance à la matière grise. Pour améliorer la détection des sillons, des points de contrôle sont introduits afin d'attirer le ruban vers l'intérieur des replis du cortex.

¹Dans cette section, nous ne considérons que l'aspect contour actif de cette approche, par ailleurs classifiée en tant qu'approche coopérative.




Fig. 14 The trajectories of the control points.



Fig. 15 The final curve obtained using ACAR and control points.

FIG. 2.4: Exemple de l'utilisation des contours actifs en segmentation du cortex, avec ajout de contraintes spécifiques pour les sillons. Extrait de [Davatzikos 95]

Des applications ont été envisagées pour représenter les sillons corticaux. Ainsi, les contours actifs ont été utilisés dans le cadre de la paramétrisation des sillons. Dans [Davatzikos 97], les contours des sillons sont initialisés à la surface d'un cerveau déjà segmenté, aux points de courbure minimale. Puis les contours sont soumis à des forces externes les attirant vers l'intérieur du cerveau. L'ensemble des positions successives occupées par un contour lors de sa déformation est utilisé pour construire une surface paramétrée représentant le sillon étudié.

Barillot & al. [Barillot 98] proposent une approche similaire pour la représentation numérique des sillons corticaux.

Dans [Sandor 97], une extension des contours actifs en 3D est utilisée pour la représentation de surfaces déformables.

L'intérêt de ces applications réside dans la définition des fonctions d'énergie qui doivent permettre au contour de rester entre deux surfaces corticales tout en étant attiré vers l'intérieur du cerveau.

Ces considérations peuvent être appliquées à la définition de fonctions de guidage de contours déformables fondés sur d'autres principes algorithmiques. Nous présenterons dans la partie 4.2 un principe de détection de contours fondé sur des principes de programmation dynamique et de minimisation d'une fonction de coût en partie inspiré par les contours actifs.

► Bilan sur les modèles énergétiques

Malgré les différents apports effectués dans les approches proposées, l'utilisation des contours actifs reste délicate en IRM cérébrale. Les problèmes d'initialisation limitent souvent l'au-

tomatisation complète des approches. De plus, la recherche d'une fonction d'énergie adéquate se rapproche de la recherche d'une modélisation énergétique globale de l'image, ce qui n'est pas nécessairement possible étant donnée la complexité des variations locales d'intensité.

2.2.2 Modèles paramétriques

On peut distinguer deux principaux types d'approches pour la modélisation paramétrique des contours. Le premier type d'approche définit la paramétrisation des objets sans utiliser de connaissance *a priori* sur le domaine de variation des paramètres. Le second type d'approche exploite les exemples issus d'un ensemble d'apprentissage pour définir et contraindre le domaine de variation des paramètres.

Le choix d'une paramétrisation est un élément crucial dans ce type d'approche. En effet, l'ensemble des formes qui peuvent être décrites par une paramétrisation est directement lié au choix de cette paramétrisation. Le choix de paramètres peut introduire indirectement des contraintes de convexité, de lissage souhaitables ou non. La paramétrisation est donc souvent liée au domaine d'application.

2.2.2.1 Modèles sans connaissance a priori

➤ Staib & Duncan

[Staib 92] ont proposé une paramétrisation fondée sur les coefficients de Fourier pour décrire des éléments présents dans des images biomédicales.

Une courbe est représentée par une combinaison linéaire de fonctions $\phi_k(t)$, sur l'intervalle $[a, b]$:

$$X(t) = \sum_{k=1}^{\infty} p_k \phi_k(t) \quad (2.25)$$

où

$$p_k = \int_a^b X(t) \phi_k(t) dt \quad (2.26)$$

La somme est tronquée et la base de fonctions classiquement utilisée est l'ensemble des fonctions sinusoidales.

$$\phi = \left\{ \frac{1}{2\pi}, \frac{\cos(x)}{\pi}, \frac{\sin(x)}{\pi}, \frac{\cos(2x)}{\pi}, \frac{\sin(2x)}{\pi}, \dots \right\} \forall t \in [a, b] \quad (2.27)$$

Dans ce cas, la représentation de la courbe sur l'intervalle $[0, 2\pi]$ devient :

$$\begin{bmatrix} x(t) \\ y(t) \end{bmatrix} = \begin{bmatrix} a_0 \\ b_0 \end{bmatrix} + \sum_{k=1}^{\infty} \begin{bmatrix} a_k & b_k \\ c_k & d_k \end{bmatrix} \begin{bmatrix} \cos(kt) \\ \sin(kt) \end{bmatrix}$$

Le contour peut ainsi être vu comme une composition d'ellipses de tailles et d'axes variables. La recherche d'un contour est une recherche de maximum *a posteriori* d'une fonction objectif décrivant le bruit de l'image ainsi que la force des contours. Cette approche a été appliquée à la recherche du corps calleux dans des coupes sagitales du cerveau.

Cependant, l'utilisation d'une modélisation fondée sur des courbes géométriques admet des limites. La géométrie des contours du cerveau étant celle d'un organe naturel, certaines parties ne sont pas représentables par des fonctions mathématiques. Une telle approche ne peut donc être envisagée que pour des courbes relativement régulières telles que par exemple le corps calleux.

➤ Bardinet

[Bardinet 95] a proposé une paramétrisation en 3D par des superquadriques. Cette approche permet de segmenter des structures cardiaques et a surtout pour objectif de les représenter par des surfaces, afin d'en fournir une représentation compacte (taux de compression de 46 pour des images 3D du ventricule gauche du cœur). L'association automatique de cette approche avec un algorithme de segmentation serait d'un grand intérêt.

2.2.2.2 Modélisation avec connaissance a priori

L'introduction de connaissance *a priori* à partir d'un ensemble d'apprentissage permet de mieux contraindre l'espace de variation des paramètres utilisés pour la modélisation.

L'intérêt de la construction de modélisations paramétriques des formes est de pouvoir disposer de représentations synthétiques et génériques des objets d'une classe donnée. La connaissance issue des ensembles d'apprentissage est ainsi uniformisée au sein de modèles mathématiques et permet d'associer la détection des objets à leur interprétation sémantique, ce qui est précieux dans une perspective d'analyse et d'exploitation des résultats ainsi produits.

➤ Cootes & al.

[Cootes 95] ont proposé une approche à base de modèles statistiques déformables fondée sur l'existence d'un ensemble d'apprentissage. Les exemples issus de l'ensemble d'apprentissage sont normalisés et la forme moyenne du modèle est la moyenne des exemples. Les modes de déformation du modèle sont calculés par une Analyse en Composantes Principales (ACP) sur la matrice de covariance des exemples. Cette approche sera décrite en détail dans la partie 3.2.

➤ Duta et Sonka

[Duta 98] proposent une extension de l'approche de Cootes qui ajoute de la connaissance *a priori* (force des contours, localisation moyenne d'un contour, relations entre contours) pour améliorer le processus de localisation ainsi que la détection des formes non valides.

➤ Szekely & al.

[Szekely 96] ont proposé une approche proche de celle de Cootes. Un modèle du corps calleux est construit à partir d'exemples, et chaque exemple est représenté par une paramétrisation de Fourier (voir 2.2.2.1). L'ensemble des exemples est normalisé et les paramètres de Fourier moyens calculés. Pour décrire les modes de variations, une ACP est effectuée sur la matrice de covariance des coefficients de Fourier normalisés. La recherche d'une occurrence du corps calleux est effectuée à l'aide de "Fourier snakes". Le principe est d'optimiser les coefficients de Fourier par une recherche de minimum énergétique tout en contraignant la variation des coefficients dans l'intervalle de variation défini par les vecteurs propres issus de l'ACP. Ainsi, la recherche est limitée à des contours qui sont biologiquement plausibles en termes de déformations.

► Bilan sur les modèles paramétriques

L'intérêt d'intégrer de la connaissance *a priori* dans un modèle déformable apparaît clairement pour la détection de contours spécifiques. Cependant, les modèles présentés dans cette partie ne permettent pas de décrire des spécificités individuelles ; c'est le cas en particulier des formes à topologie variable comme les sillons corticaux. Il apparaît donc que de tels modèles sont précieux pour localiser de façon robuste un ensemble de contours chez un grand nombre d'individus. Cependant, afin d'affiner la détection des contours nous pensons qu'il est nécessaire de combiner l'information issue d'un modèle avec une information plus spécifiquement liée à l'image étudiée.

2.2.3 Autres modèles

Des modélisations non paramétriques et non énergétiques ont également été proposées pour segmenter les IRM cérébrales comme [Collins 95] ou encore les approches fondées sur des atlas [Mazziota 95] [Barillot 97] plutôt orientées vers la mise en correspondance de plusieurs cerveaux dans un référentiel commun.

➤ Modélisation avec connaissance a priori issue d'un exemple unique :

Collins & al [Collins 95] proposent une approche pour la segmentation du cerveau humain en 3 classes de tissus (matière grise, matière blanche et liquide céphalo-rachidien)

fondée sur un modèle constitué par *un seul exemple* en 3D. L'exemple est un couple constitué d'une image en niveaux de gris A et de sa segmentation AS, qui à chaque pixel de A associe sa classe dans l'image segmentée. Le couple (A, AS) représente la connaissance *a priori* et c'est également le modèle. La segmentation d'une nouvelle image B est effectuée en 2 étapes. La première étape consiste à rechercher la meilleure transformation (linéaire puis non-linéaire) qui permet de mettre en correspondance A et B (en niveaux de gris) grâce aux informations sur l'intensité et le gradient. A partir de cette transformation optimale, la transformation inverse est calculée puis appliquée à AS pour obtenir la segmentation BS recherchée.

Cette approche, bien que puissante, admet cependant des limites dans le cas où la topologie des deux cerveaux à mettre en correspondance diffère beaucoup.

2.3 Approches à base de connaissance

Les approches à base de connaissance constituent un ensemble d'approches spécifique bien distinct des autres types d'approches étudiés. Il est intéressant de les étudier dans une perspective de contrôle de stratégie de résolution. En effet, dans les approches précédemment étudiées (classification, modélisation) la connaissance du domaine introduite dans les systèmes est directement comprise dans le processus de segmentation. Dans le cas des systèmes à base de connaissance, l'accent est mis sur la définition et la représentation *explicite* d'un ensemble de connaissance experte dans l'objectif de guider un processus de segmentation.

L'intérêt de tels systèmes est donc de permettre une séparation entre la représentation des connaissances de contrôle et la représentation des connaissances du domaine.

L'objectif général est de sélectionner et de contraindre des opérateurs de traitement de bas-niveau à partir de systèmes de règles pour aboutir à une correspondance entre entités numériques et symboliques.

2.3.1 Approches proposées

Nous présentons d'abord deux approches proposant une modélisation du cerveau avec leur stratégie de résolution. Puis nous présentons une évolution concernant l'introduction de notions floues dans le modèle. Enfin nous présentons une approche fondée sur de la connaissance *a priori* et l'utilisation d'algorithmes génétiques dans un but d'optimisation du résultat plutôt que dans un but de contrôle de stratégie.

➤ Gong & Kulikowski

[Gong 95] proposent un système VISIPLAN pour effectuer de la génération automatique de plans. Le paradigme général est composé de 3 étapes principales (fig. 2.5).

1	Spécification de la tâche à effectuer	Objectif Images disponibles Objet de référence
2	Plan abstrait	Stratégie d'analyse générale Séquence d'objets de référence
3	Plan spécifique	Pour chaque objet de référence sélectionner : Type d'image, Méthode de segmentation Principe et opérateur de focalisation Processus de reconnaissance

FIG. 2.5: Paradigme général de la génération automatique de plans, d'après [Gong 95].

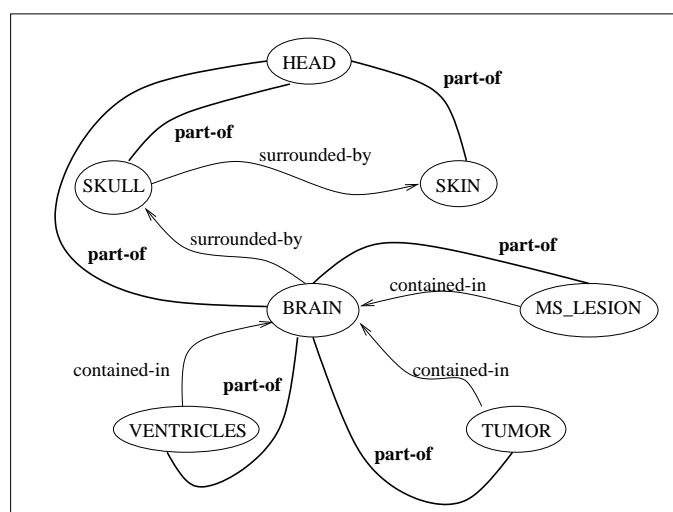


FIG. 2.6: Modélisation de la connaissance symbolique sur le cerveau utilisée pour guider le processus de segmentation. Les relations structurelles sont représentées par des traits en gras et les relations spatiales sont représentées à l'aide de flèches. D'après [Gong 95]

Les objets de référence doivent être stables spatialement ; ils doivent pouvoir être séparables du reste de l'image par une méthode de segmentation (seuillages locaux ou globaux).

La représentation des objets permet la définition de deux principaux types de connaissance : de la connaissance sur les relations structurelles entre les objets et de la connaissance sur les relations spatiales des objets entre eux.

Un réseau sémantique est exploité. Dans le cas de la segmentation du cerveau, le modèle proposé est présenté dans la figure 2.6.

En réponse à la requête d'un utilisateur (fig. 2.7) un plan pour la détection des ventricules est proposé par le système (fig. 2.8).

Goal	detect ventricules
Context	Brain
Images type	PD, T1

FIG. 2.7: Requête de l'utilisateur pour détecter les ventricules, d'après [Gong 95].

Plan proposé par le système		
1. Detect brain		
	image-type	PD
	focus	the ENTIRE-IMAGE of object brain
	focusing operator	DIRECT-ACCESS
	segmentation method	GLOBAL-S-THRESHOLDING
	recognition scheme	REGION-CLASSIFIER
2. Detect ventricules		
	image-type	PD and T2
	focus	INTERIOR of object brain
	focusing operator	DIRECT-MASKING and INTERPLANE-PROJECTION
	segmentation method	GLOBAL-M-THRESHOLDING
	recognition scheme	REGION-CLASSIFIER

FIG. 2.8: Plan proposé par le système en réponse à la requête de détection des ventricules. D'après [Gong 95].

L'approche est donc fondée sur un principe de focalisations successives pour atteindre le but d'une segmentation complète. Dans notre approche, un principe similaire de focalisation sera utilisé pour segmenter successivement les différents tissus cérébraux.

➤ Li & al.

[Li 95] proposent un modèle du cerveau intégrant de la connaissance symbolique et numérique pour guider un processus d'interprétation.

Le modèle décrit les structures du cerveau ainsi que leurs relations spatiales sous forme d'un graphe (fig. 2.9).

Les noeuds du graphe sont associés à des attributs symboliques (taille petite, moyenne,...) ou bien à des données numériques issues d'un apprentissage.

La segmentation consiste en la recherche d'une mise en correspondance entre le graphe symbolique et le résultat d'une extraction des primitives de bas-niveau. L'initialisation de

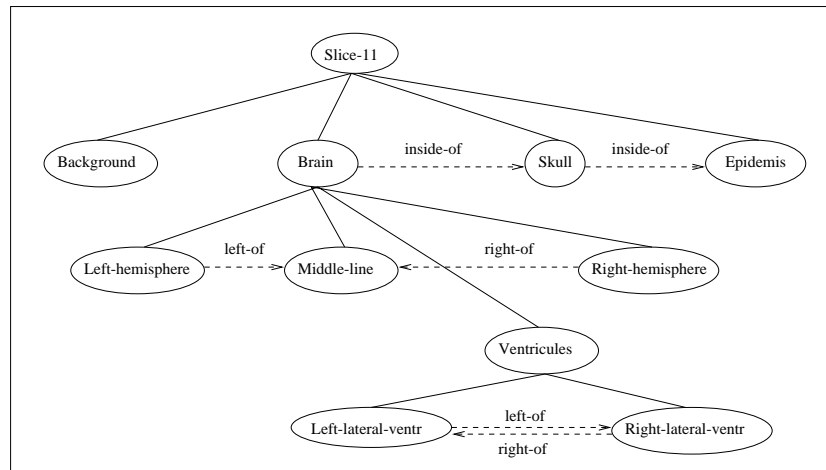


FIG. 2.9: Modélisation de la connaissance *a priori* sur le cerveau d'après [Li 95].

la mise en correspondance se fait à l'aide de points remarquables (germes) situés dans des structures de taille importante. Ces points permettent d'ancrer le graphe par rapport à l'image et d'en déduire des relations spatiales. A partir du positionnement des germes, les régions issues de l'extraction des primitives sont successivement fusionnées, en accord avec le modèle symbolique, pour obtenir une interprétation de l'image.

Le principe d'ancrage de germes, proche conceptuellement du principe de focalisation précédemment mentionné, fait également partie des principes que nous avons exploités dans notre travail de recherche de contraintes sur les positions des germes des agents spécialisés.

➤ Dellepiane & al.

[Dellepiane 91] proposent une approche guidée par la connaissance fondée sur la génération d'une modélisation floue des attributs (taille, niveau de gris moyen,...) des différents organes recherchés dans les coupes IRM.

Le principe repose sur l'extraction de primitives bas-niveau de type région, puis sur leur association à des entités symboliques. L'introduction d'une notion d'appartenance floue à un objet permet de sélectionner l'association numérique/symbolique qui présente le meilleur taux de confiance.

Le modèle décrit les attributs du domaine (taille, niveau de gris, forme, position,...) ainsi que les valeurs possibles de ces attributs (grand, petit, foncé, clair, à droite, à gauche, circulaire, périphérique, central,...). Le modèle décrit également les relations qui peuvent exister entre plusieurs attributs (plus grand que, plus petit que, devant, derrière,...).

Un ensemble d'apprentissage est utilisé ; il est constitué d'exemples segmentés où les

caractéristiques de chaque organe sont représentées symboliquement en utilisant les attributs précédemment définis.

La segmentation d'une image est effectuée en recherchant successivement les organes présents dans des IRM du cerveau, en utilisant deux modalités d'acquisition T1 et T2.

A chaque étape, l'entité recherchée correspond à l'union de régions de bas-niveau. Une fonction floue est associée à la segmentation de l'entité et le meilleur ensemble de régions décrivant cette entité est conservé.

Cette structuration des traitements permet d'affiner successivement la détection des objets en commençant par des groupes d'objets plus facilement identifiables que leurs composantes individuelles.

➤ Sonka & al.

[Sonka 96] proposent une approche à base de connaissance fondée sur l'algorithmique génétique. La connaissance est acquise à partir d'une vingtaine d'exemples où les structures d'intérêt ont été marquées par des experts. Pour chaque structure les éléments suivants sont calculés :

- niveau de gris moyen
- taille
- longueur du contour
- centre de gravité
- excentricité
- compacité
- orientation

La moyenne et la variance pour chaque structure sont insérées dans la fonction objectif de l'algorithme génétique. La population des segmentations possibles est initialisée à l'aide d'une sur-segmentation de l'image. Puis, conformément au principe des algorithmes génétiques, des croisements sont effectués entre les différents individus représentant différentes hypothèses de fusion de régions.

A chaque itération, les individus présentant la meilleure estimation par rapport à la fonction objectif sont conservés. L'approche est appliquée à la détection de 17 structures du cerveau telles que le noyau caudé, le thalamus, le système ventriculaire,...

Cette approche est donc originale dans le sens où la connaissance n'est pas utilisée pour contrôler le processus de rétroaction mais plutôt pour en évaluer la qualité. L'utilisation de l'algorithmique génétique renforce la notion de liberté d'exécution laissée au système.

► Bilan sur les approches à base de connaissance :

L'intérêt des approches à base de connaissance que nous avons présentées réside donc principalement dans leur capacité à tirer parti de modèles de connaissance pour contrôler des processus de segmentation.

Contrairement aux approches utilisant des procédés de classification, la connaissance utilisée est explicitement décrite. Cela permet de mieux appréhender les besoins de connaissance *a priori* ainsi que les moyens nécessaires pour passer de la connaissance au traitement des données.

2.4 Approches coopératives

Au cours de l'étude des approches par classification (section 2.1), puis par utilisation de modèles déformables (section 2.2), nous avons noté que certaines phases de traitement étaient délicates. Dans le cadre de la classification, par exemple, la nécessité de définir une région d'intérêt est fondamentale pour réduire le nombre de classes à classifier. De même, le choix d'une stratégie de résolution, lorsqu'elle n'est pas guidée par un ensemble de connaissance *a priori* (section 2.3) n'est pas évident.

L'intérêt de faire coopérer plusieurs approches est donc de réussir à définir automatiquement des ensembles de contraintes pour guider les processus de segmentation. La stratégie de résolution peut donc être séquentielle, c'est-à-dire exploiter successivement le résultat d'une approche pour en guider une autre, ou bien itérative, c'est-à-dire fondée sur un principe réciproque de définition de contraintes.

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 d'"itératives", fondées sur une définition mutuelle de contraintes et qui permettent une émergence de la solution.

2.4.1 Coopération séquentielle

Les approches que nous présentons dans cette section sont principalement fondées sur des principes de focalisations successives et de corrections de résultats intermédiaires. L'objectif est de réduire progressivement la difficulté du problème en le décomposant en sous parties de

plus en plus fines.

➤ Kapur & al.

[Kapur 96] présentent une méthode de segmentation composée de trois principales phases :

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 E/M proposée dans [Wells 96] et décrite dans la section 2.1.1.2. 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, ...). 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. Comme décrit en section 2.2.1.2, 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. La propagation du contour actif de coupe en coupe permet de réaliser la segmentation en 3D.

➤ Warfield & al.

[Warfield 95] proposent une coopération séquentielle pour détecter les lésions de la matière grise. Leur approche est très similaire à celle proposée dans [Johnston 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 du cerveau et tissus non cérébraux par classification. Cette étape est affinée par un processus d'érosion/dilatation pour éliminer les connexions entre cerveau et crâne.
2. La seconde étape fait appel à la classification adaptative par E/M proposée dans [Wells 96] (décrite dans la section 2.1.1.2).
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 voxels 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 si l est classifié comme matière grise
 - et si l n'est pas un maximum de gradient alors
 - marquer l comme cortex
 - 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.

➤ Teo et Wandell [Teo 97] proposent une segmentation en deux étapes principales qui permettent de contraindre la topologie de la matière grise (fig. 2.10).

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.

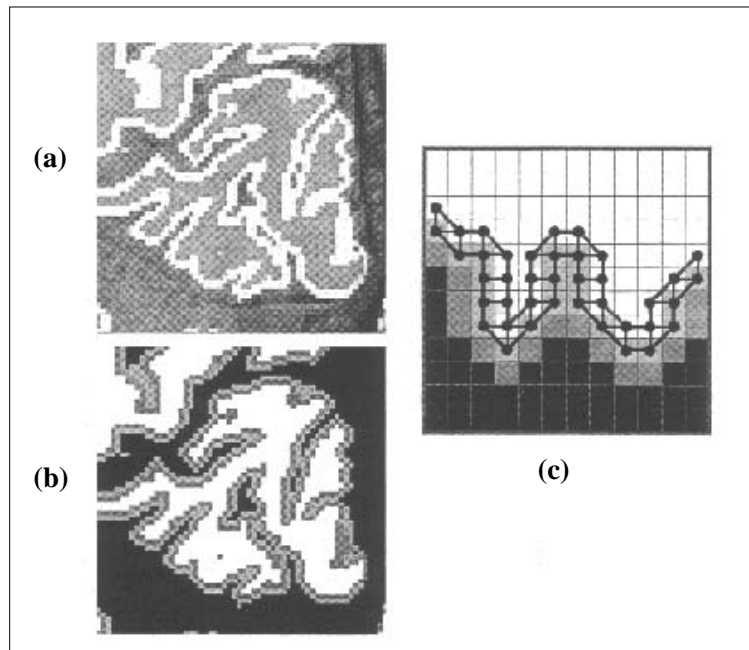


FIG. 2.10: Approche proposée par Teo et Wandell pour assurer la topologie de la matière grise. (a) Superposition de la matière grise détectée sur l’image originale. (b) Résultat de la segmentation de la matière blanche et de la matière grise. (c) Principe de croissance de la matière grise autour de la matière blanche.

► Bilan sur la coopération séquentielle :

L’utilisation d’un certain nombre de modules, 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’a écrit Kapur dans [Kapur 96] :

“We present our method for segmentation of brain tissue that combine the strengths of some of the existing technology with some new ideas and that is more robust than its individual components”

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

2.4.2 Coopération itérative

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 peu d'approches proposant un tel type de coopération pour la segmentation. Nous présentons ici des approches fondées sur la théorie des jeux de Nash dont nous rappelons les principes essentiels [Bozma 92].

2.4.2.1 Eléments sur la théorie des jeux de Nash

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.

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 F_i de coût ont la structure suivante :

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

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

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.

$$p_1^{k+1} = \min_{p_1} F_1(p_1, p_2^k)$$

$$p_2^{k+1} = \min_{p_2} F_2(p_1^k, p_2)$$

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. On note (\bar{p}_1, \bar{p}_2) la solution optimale :

$$\forall (p_1, p_2) \begin{cases} F_1(\bar{p}_1, \bar{p}_2) \leq F_1(p_1, \bar{p}_2) \\ F_2(\bar{p}_1, \bar{p}_2) \leq F_2(\bar{p}_1, p_2) \end{cases} \quad (2.28)$$

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 module de segmentation, on peut en effet envisager un schéma d'optimisation itératif (fig. 2.11). 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.




FIG. 2.11: Schéma d'optimisation itératif.

2.4.2.2 Approches proposées

➤ Bozma et Duncan

[Bozma 94] présentent une approche fondée sur la théorie des jeux pour contrôler un processus de coopération entre 2 modules de détection de contours.

Le rôle du Module 1 est de détecter localement des structures pouvant représenter des contours et le rôle du Module 2 est de détecter globalement un contour 2D.

La sortie du Module 1 est représentée par l'ensemble des structures de contours localement détectées et la sortie du Module 2 est constituée des paramètres du contour 2D.

La fonction objectif du Module 1 consiste à :

1. Renforcer les structures locales de contours et éliminer le bruit par la mise en correspondance des contours locaux déjà trouvés avec un modèle local de curvilinearité.

2. Assurer la cohérence avec le résultat du Module 2, principalement par corrélation entre les résultats des 2 modules.

La fonction objectif du Module 2 consiste à :

1. Trouver un modèle déformable du contour.
2. Assurer la cohérence avec le résultat du Module 1. L'objectif est de parcourir le contour paramétré, en pénalisant la traversée de contours bas-niveau faibles et en favorisant la traversée de contours bas-niveau forts.

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

➤ Chakraborty et Duncan

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

Le Module 1 sert à la détection des régions homogènes de l'image. Le principe utilisé est celui des champs de Markov [Cocquerez 95]. Le principe de la fonction objectif du Module 1 est de :

1. Segmenter la région X connaissant l'image Y, ce qui est équivalent à maximiser la probabilité suivante :

$$\max_X P(X|Y)$$

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 $\max P(X|Y, p)$ représente l'influence du contour sur la région X (fig. 2.12).

Le Module 2 sert à la détection des contours. Il 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 $\max_p P(p|G, X)$ d'avoir le contour p connaissant non seulement le gradient mais aussi la segmentation région X (fig. 2.12).

► Bilan sur les approches coopératives itératives :

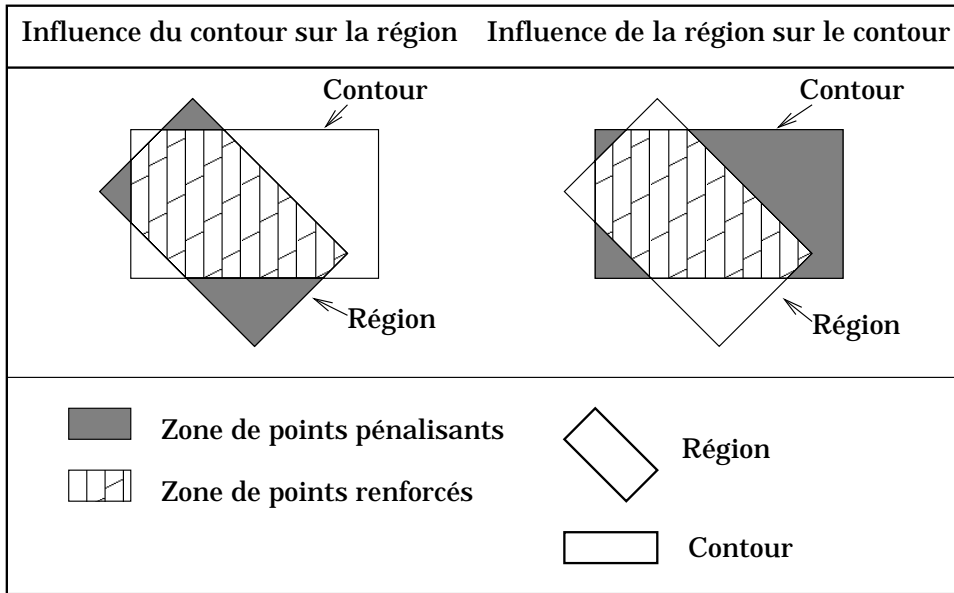


FIG. 2.12: Influence du contour p sur l'évaluation du module région, et réciproquement de la région sur le contour.

Il est intéressant, pour clore cette étude, de rappeler la comparaison effectuée entre 3 systèmes d'analyse d'image dans [Chakraborty 99]. Dans les 3 cas, les systèmes présentés sont multi-modules et ont pour objectif l'optimisation des paramètres de chaque module. La distinction est faite entre :

1. Un schéma d'optimisation globale pour lequel :

$$(p_1^*, p_2^*) = \underset{(p_1, p_2)}{\operatorname{argmin}} (\gamma_1 F_1(p_1, p_2) + \gamma_2 F_2(p_1, p_2))$$

2. Un schéma d'optimisation séquentiel :

$$p_1^* \in \underset{(p_1)}{\operatorname{argmin}} (F_1(p_1, p_2^*)) \rightarrow p_2^* \in \underset{(p_2)}{\operatorname{argmin}} (F_2(p_1^*, p_2))$$

3. Un schéma d'optimisation parallèle (adopté en théorie des jeux) :

$$\begin{cases} p_1^* \in \underset{(p_1)}{\operatorname{argmin}} (F_1(p_1, p_2^*)) \\ p_2^* \in \underset{(p_2)}{\operatorname{argmin}} (F_2(p_1^*, p_2)) \end{cases} \quad (2.29)$$

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

Conclusion

Dans ce chapitre, nous avons présenté un état de l'art couvrant un vaste ensemble d'approches dédiées à la segmentation en IRM cérébrale. Nous avons présenté :

- Les approches par classification, utilisant des modèles locaux, principalement exploitées pour la détection de régions homogènes.
- Les approches utilisant des modèles globaux, essentiellement dédiées à la recherche de contours d'objets.
- Les approches à base de connaissance permettant de définir des stratégies de contrôle de la segmentation à partir de la modélisation explicite de connaissance du domaine.
- Les approches coopératives ayant des objectifs plus globaux pour la réalisation de systèmes de segmentation complets.

Il est intéressant et à la fois difficile, à l'issue de ce chapitre, d'effectuer un bilan global à partir des différents bilans effectués pour chaque type d'approche étudié. En effet, il semble que deux notions antinomiques se dégagent de ces bilans.

D'une part, nous avons insisté à plusieurs reprises sur la difficulté du problème posé et évoqué à ce sujet la nécessité de définir et de mettre en oeuvre un ensemble de contraintes pour guider les processus de segmentation. Plus particulièrement, il est important de définir les modalités de l'introduction de connaissance *a priori* au sein des systèmes de segmentation pour définir des stratégies de résolution et de tirer parti des connaissances acquises antérieurement pour améliorer les prises de décision.

D'autre part, il est apparu à plusieurs reprises que l'existence de contraintes trop fortes pouvait limiter l'efficacité de la segmentation et par conséquent qu'il pouvait être bénéfique d'accorder aux systèmes une certaine liberté d'exécution, liée à la notion d'émergence d'une solution. Plus particulièrement, l'utilisation des traitements globaux ou de modélisations peu adaptatives peuvent réduire les performances d'une approche.

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.

L'approche que nous proposons dans cette thèse s'inscrit dans ce cadre difficile de contraintes et de liberté d'exécution. L'utilisation d'une approche multi-agents répond particulièrement bien à la double exigence précisée ci-dessus. 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 qui échappe à un contrôle global ou centralisé. En ce sens, la solution émerge sans intervention

extérieure.

Le comportement du système est incrémental pour permettre un affinement progressif de la segmentation. Ainsi, nous intégrons dans un premier temps une approche fondée sur un modèle de contour déformable avec une approche multi-agents pour la détection des régions. Puis, nous intégrons une approche de détection de contours pour affiner le contour détecté par le modèle, en accord avec le résultat obtenu pour les régions.

Le principe de l'intégration de plusieurs méthodes permet de construire des ensembles de contraintes en réponse aux difficultés du problème.

Grâce à sa capacité à générer des contraintes et à son incrémentalité, l'approche que nous présentons dans la suite de ce document est automatique et adaptative.

Chapitre 3

Modules de base du système

Introduction

L'ensemble de notre approche est fondé sur la mise en oeuvre d'interactions entre différents modules. L'objectif est d'utiliser au mieux les capacités de plusieurs approches afin de pouvoir, grâce à des mécanismes d'interaction, proposer un principe de segmentation autonome, adaptatif et efficace.

Afin de mieux préciser les interactions qui entrent en jeu entre les différents modules, nous avons réalisé le schéma 3.1. Ce schéma présente une vue synthétique de l'ensemble de l'approche du point de vue des interactions entre modules. Il permet de mieux envisager le rôle joué par chacun des modules qui seront décrits dans ce chapitre.

Ainsi, le module correspondant au modèle déformable permet d'initialiser la partie "Agents régions" du module "Agents".

Le module de détection de contours, couplé au résultat de la détection des régions dans un cadre de fusion d'informations permet l'initialisation d'agents contours pour reconstruire une enveloppe du cerveau ou bien envisager la détection des sillons.

Enfin, la partie "Agents contours" du module "Agents" permet de générer des contours qui pourront être ré-injectés en entrée de la partie "Agents régions" du module "Agents" dans un cadre de rétroaction, en remplacement du modèle déformable.

Le schéma permet donc de synthétiser l'ensemble des interactions entre modules et de mieux saisir le rôle fondamental joué par chacun d'eux. On pourra noter ici que le rôle du système multi-agents apparaît comme central dans l'ensemble du système.

Notre contribution principale dans ce chapitre concerne le module "Agents" que nous avons entièrement défini et mis en oeuvre. Le module "Modèle" a nécessité une formation spécifique à l'utilisation et l'intégration des outils qui sont présentés. Enfin le module "Détecteur de con-

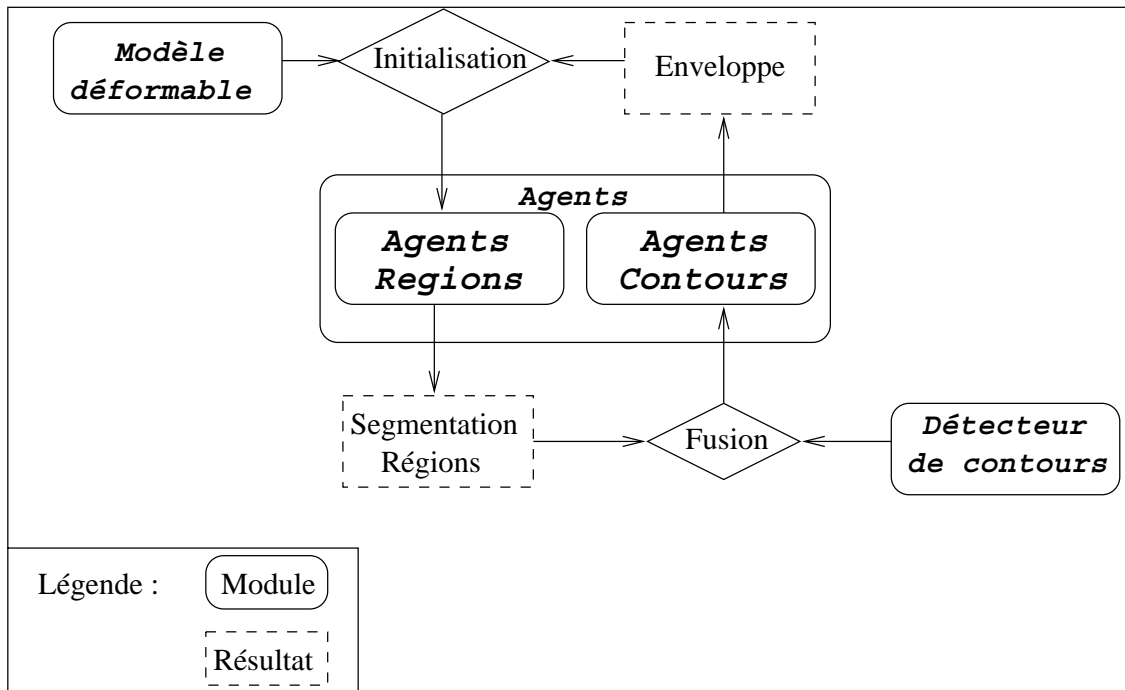


FIG. 3.1: Interaction entre modules de base du système.

tours” a été intégré au sein d’une librairie indépendante, à partir du code source fourni par A. Chehikian (LIS, Grenoble).

3.1 Module “Agents”

3.1.1 Intérêt et difficultés

L’un des modules de base de notre système est fondé sur des principes d’intelligence artificielle distribuée. Plus particulièrement, nous exploitons un principe de modélisation multi-agents pour initialiser, contraindre et exécuter des agents de segmentation.

Le domaine des systèmes multi-agents concerne la définition et l’étude d’agents autonomes capables de communiquer et d’agir sur leur environnement pour effectuer une ou plusieurs tâches.

Lors de la mise en oeuvre de tels systèmes, le principal effort réside dans la répartition des tâches entre les agents ainsi que la définition de leurs comportements pour obtenir la solution du problème posé. Il est donc nécessaire de définir un modèle d’agent, le comportement associé ainsi qu’un protocole de communication inter-agents.

La notion de distribution de l’activité est justifiée dans [Ferber 95] par la distribution physique

des problèmes, leur hétérogénéité et leur complexité. Les aspects d’adaptativité peuvent également être pris en compte dans de tels systèmes, ce qui est intéressant dans le contexte de l’inhomogénéité des niveaux de gris en IRM.

Dans [Brooks 91], Brooks propose une description en termes de comportement des caractéristiques (fig. 3.2) qu’il serait souhaitable de trouver dans un système composé d’agents :

1	A creature must cope appropriately and in timely fashion with changes in its dynamic environment.
2	A creature should be robust with respect to its environment ; minor changes in the properties of the world should not lead to total collapse of the creature’s behavior ; rather one should expect gradual changes in capabilities of the creature as the environment changes more and more.
3	A creature should be able to maintain multiple goals and, depending on the circumstances it finds itself in, change which particular goals it is actively pursuing ; thus it can both adapt to the surroundings and capitalize on fortuitous circumstances.
4	A creature should do <i>something</i> in the world ; it should have some purpose in being.

FIG. 3.2: Caractéristiques souhaitées pour un agent d’après [Brooks 91].

Une telle liste de caractéristiques, initialement plutôt destinée à la robotique, s’adapte bien au problème de la segmentation. En résumant la requête de Brooks par :

“ Les agents doivent avoir des comportements cohérents, adaptés aux situations rencontrées et menant à l’exécution d’une fonctionnalité”

on conçoit bien l’intérêt d’exploiter une telle conception pour la segmentation.

En effet, la cohérence des comportements doit s’exprimer à travers des similarités de comportement entre des agents générés dans le but de réaliser une même tâche (segmentation distribuée d’un tissu par plusieurs agents par exemple).

L’agent doit s’adapter aux situations rencontrées. Cet aspect concerne plutôt la spécialisation des agents qui doit leur permettre d’avoir un comportement en adéquation avec le problème posé. Par exemple en IRM, les agents doivent garder le même comportement quelle que soit la séquence d’acquisition choisie.

Enfin, les agents doivent exécuter une fonctionnalité, c’est-à-dire participer à la résolution d’un des buts du problème posé, comme la détection d’un tissu ou d’un contour.

Nous avons retenu 3 axes principaux qui nous semblent essentiels dans les systèmes multi-agents pour une application à la segmentation :

distribution : L'introduction de distribution dans le système permet de répartir les tâches et de spécialiser localement les agents mis en oeuvre afin d'obtenir une meilleure réaction à l'environnement [Ferber 95]. La distribution (différente d'une parallélisation) permet également d'exploiter la simultanéité d'exécution d'un ensemble d'agents et de tirer parti de l'émergence progressive d'une solution.

adaptation : Pour réaliser un système répondant aux caractéristiques citées ci-dessus, Brooks propose que les agents fonctionnent en réaction à un environnement dynamique, dans un monde non modélisé. Dans le cadre d'un système de segmentation, une telle proposition semble tout à fait appropriée. En effet, un ensemble d'images possédant des caractéristiques variées constitue un environnement changeant dans lequel toute modélisation complète est quasi-impossible.

contrôle : Les modèles de systèmes multi-agents proposent généralement d'abandonner l'idée d'un contrôle global. Par exemple, le schéma architectural de Brooks propose de laisser émerger des fonctionnalités à partir d'un ensemble de comportements par opposition à une architecture planifiée qui définit des comportements à partir de fonctionnalités.

Plus précisément, l'absence de contrôle global revient à laisser une population d'agents s'auto-organiser afin d'aboutir à une solution.

Cela suppose une grande capacité de communication entre agents or dans l'état actuel des recherches en ce domaine (Bulletin de l'AFIA, [Afia 97]), la communication reste un problème majeur à résoudre.

Dans ce travail nous avons focalisé notre attention sur les aspects de distribution et d'adaptation. La communication directe entre agents, permettant en théorie une absence de contrôle global, a été remplacée par un environnement partagé des connaissances permettant l'ajustement des comportements des agents.

3.1.2 Nécessité de contraindre

La mise en oeuvre d'un tel système n'est pas évidente en termes de définition des contraintes à appliquer. Pour illustrer cette difficulté nous présentons dans l'image 3.3 un exemple de résultat obtenu au début de nos recherches.




FIG. 3.3: Résultat de segmentation pour un système autonome sans contraintes spécifiques.

Dans cet exemple, le système a positionné un nombre fixé à l’avance d’agents contours et régions. Les agents contours ont débuté en des points de maximum local de gradient et les agents région en des points de variance minimale, tous automatiquement choisis. Les contraintes d’agrégation étaient un seuil minimal sur le gradient des points candidats pour les contours et un seuil maximal de variance pour chaque région.

Il apparaît clairement au vu de ce type de résultat que l’utilisation “brute” et autonome d’un système multi-agents, dans le but de segmenter une IRM cérébrale, ne peut donner de résultats suffisants et exploitables. C’est à ce stade du travail qu’est apparue une notion essentielle dans toute la suite de nos recherches : **la nécessité de CONTRAINDRE**. On peut coupler cette notion avec celle de spécialisation, également fondamentale pour permettre l’exploitation des résultats.

3.1.3 Des agents contours et régions

Dans ce travail nous avons exploité deux grands types d’agents de segmentation : des agents de croissance de région et des agents de croissance de contours. Pour les agents de type “région” le principe est de définir un pixel initial appelé **germe**. Puis, itérativement, d’examiner la frontière de la zone en cours de construction et de choisir d’agréger à la région un pixel selon des critères à définir.




FIG. 3.4: (a) Principe itératif de la croissance de régions. (b) Principe itératif de la croissance de contours.

La croissance d'une région cesse lorsqu'aucun des pixels de la frontière ne vérifie les critères d'agrégation.

Les agents de type contours sont également définis à partir d'un germe et effectuent une croissance en examinant les pixels situés aux extrémités du contour en cours de construction. A chaque étape, le pixel vérifiant au mieux un critère d'agrégation est sélectionné parmi les candidats potentiels et agrégé au contour. Comme pour les agents région, la croissance cesse lorsqu'aucun des pixels candidats ne satisfait le critère d'agrégation.

3.1.3.1 Sources d'information

L'ensemble des sources d'information disponibles pour contraindre les agents est constitué essentiellement par quatre types d'information :

1. **L'image source.** Cette information est évidemment indispensable à tout processus de segmentation. Elle permet de réaliser le lien avec les données. C'est une information de type intensité des niveaux de gris qui décrit également les relations spatiales entre pixels.
2. **Le modèle déformable.** Il s'agit en fait du résultat issu de la recherche du modèle déformable dans l'image étudiée. C'est une information de type contour.
3. **Le résultat de la segmentation en régions.** Cette source d'information est issue de traitements sur l'image étudiée. Le principe d'utilisation de ce type d'information permet d'introduire des notions de connaissance à des stades ultérieurs de traitement. C'est une information de type binaire, qui précise pour chaque pixel sa classe d'appartenance. Une perspective de ce travail est le remplacement de l'étiquetage binaire par un étiquetage probabiliste, dans le cadre de la rediscussion des affectations des pixels, pour une prise en compte des effets de volumes partiels. Toutefois, la mise en oeuvre de processus de rediscussion pose le problème du choix de mesures telles que la comparaison soit possible entre les évaluations de deux pixels. Un tel choix n'est pas évident et nécessiterait une étude spécifique.

4. **Le détecteur de contours.** Il s’agit en fait du résultat issu du détecteur de contours. L’information est de type contour et issue de traitements de bas-niveau sur les données image.

Selon la nature et la spécialisation des agents, certaines sources seront privilégiées pour l’intérêt qu’elles représentent. Ainsi, la figure 3.5 présente les sources d’information utilisées par les agents de type région et les agents de type contour.

Dans chaque cas, on notera la complémentarité des sources utilisées en termes de régions et de contours.

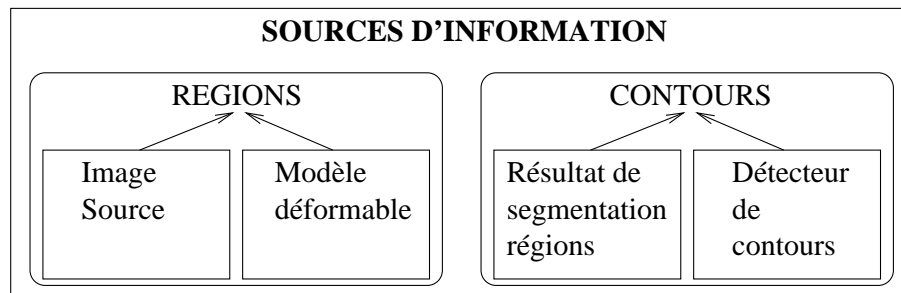


FIG. 3.5: Sources d’information utilisées selon le type d’agent.

3.1.3.2 Trois spécialisations

Dans le contexte de la segmentation en IRM cérébrale, nous avons défini 3 grands types d’agents spécialisés :

1. Agents matière grise
2. Agents matière blanche
3. Agents A*

Les deux premiers types d’agents sont des agents de croissance de région. Ils sont définis à partir d’un modèle générique d’agent région. Les agents A* sont fondés sur un algorithme de programmation dynamique et servent à la détection du contour du cerveau.

Remarque : La terminologie choisie pour décrire ces agents est directement liée au fait que ces agents sont fondés sur la programmation dynamique.

3.1.4 Modèle générique d’agent région

Le modèle générique d’agent région est un modèle à deux paramètres (μ, σ) calculés dynamiquement et associés à un pixel germe G (fig. 3.6).

Agent Région	AR
Germe	G
Comportement	(μ, σ)

FIG. 3.6: Modèle générique d’agent pour la segmentation en régions.

Les paramètres (μ, σ) permettent de définir un critère d’agrégation pour la croissance de région. Un pixel p , d’intensité I_p sera agrégé à la région construite par l’agent AR si il vérifie l’une des 2 conditions :

- il possède 3 voisins en 4 connexité déjà agrégés par AR
- il vérifie l’équation (3.1).

$$\mu - \alpha * \sigma \leq I_p \leq \mu + \alpha * \sigma \quad (3.1)$$

Le coefficient α est fixé à une valeur de 1.5 pour toute image. Dans le cadre d’une modélisation gaussienne de la distribution du tissu en cours de segmentation, en considérant le couple (μ, σ) comme paramètre de la fonction gaussienne, cela revient à considérer que 90% environ de la distribution se trouve entre les bornes fixées dans l’équation 3.1.

Dans l’implantation actuelle du système, le coefficient α est fixe et ne varie pas pendant le processus de croissance des régions.

Le modèle générique d’agent ne précise pas comment la position du germe est déterminée. Cependant, ce positionnement est un point essentiel puisque l’interprétation sémantique de la zone segmentée par un agent région est directement associée à sa position initiale.

Ainsi, pour segmenter une zone de matière grise, les germes des agents correspondant doivent être positionnés dans la matière grise. Le problème du positionnement n’est donc pas trivial et sera résolu dans un cadre coopératif décrit au chapitre 4.

Le calcul des paramètres (μ, σ) dépend du type d’agent et sera détaillé lors de la présentation des agents spécialisés.

3.1.5 Modèle générique d’agent A*

⇔ Limites des agents contours “classiques” :

L’utilisation de contours “classiques” dont un comportement est présenté dans la figure 3.4 permet d’extraire de l’information sur la localisation des contours principaux de l’image.

Cependant, de tels agents ne permettent pas de *structurer* l'information pour une utilisation ultérieure. Par exemple, on ne peut pas connaître ni fixer à l'avance un ensemble de pixels qui seront contenus dans un contour. C'est principalement l'absence de capacité de structuration qui nous a amenés à considérer l'utilisation de la programmation dynamique pour la recherche de contours structurés.

Les agents contours "A*" :

La notion d'agents A* est inspirée de celle des "live-wire boundaries" présentés par Barrett et Mortensen dans [Barret 97]. Plus antérieurement, le principe est issu des travaux de Martelli [Martelli 76] portant sur l'application des méthodes d'exploration de graphes à la détection des contours.

Les agents A* sont donc plus proches conceptuellement des contours actifs que d'agents contours "classiques". En effet, les agents A* sont associés à des processus d'optimisation plutôt qu'à des processus de croissance itérative.

Ces agents A* ne sont cependant pas semblables aux contours actifs. Ils diffèrent en plusieurs points importants :

1. **L'initialisation** : Les contours actifs doivent être initialisés par une estimation continue du contour à détecter alors que les contours A* sont initialisés par les positions (fixes) de leurs 2 extrémités.
2. **L'optimisation** : Les contours actifs sont associés à une optimisation globale de l'énergie sur l'ensemble de l'image alors que les contours A* sont associés à une optimisation locale. Ainsi, il est possible de détecter un contour fermé à l'aide de plusieurs contours A* adjacents. La détection effectuée sera alors optimale pour chaque segment correspondant chacun à un agent A*.

On peut définir un modèle générique d'agent A* (fig. 3.7) grâce à la donnée de 2 pixels qui constitueront les extrémités du contour recherché ainsi que la donnée d'une fonction de coût qui permettra de calculer le chemin optimal entre les 2 extrémités.

Agent A*	AA*
Pixels Extrémités	(p_1, p_2)
Fonction de coût	f

FIG. 3.7: Modèle générique d'agent A*.

Principe algorithmique :

Nous rappelons le principe algorithmique (fig. 3.8) qui permet de rechercher le contour optimal correspondant à un agent A^* .

Dans le cadre de l'exploration de graphes, l'algorithme A^* utilise une fonction de coût de la forme :

$$f(n) = g(n) + h(n)$$

où $g(n)$ est une estimation du coût minimal entre le noeud initial s et le noeud courant n , et $h(n)$ est une estimation minorante du coût entre le noeud n et le noeud objectif g . Le coût d'un arc du graphe est noté $c(n, n_i)$. Dans le cas où h est la fonction constante nulle, l'algorithme A^* coïncide avec l'algorithme de Dijkstra.

Fonction de coût :

Comme pour les contours actifs une difficulté importante dans l'utilisation des agents A^* est de définir une *bonne* fonction de coût. Le problème sera abordé dans la partie 4.2 dans un cadre de fusion d'informations.

3.1.6 Architecture du système multi-agents

Le choix d'une architecture pour l'implantation du module "Agents" a été guidé par les travaux réalisés par Boucher [Boucher 98] et Bellet [Bellet 95]. Ces travaux ont permis de définir un cadre informatique adapté pour la représentation des agents ainsi que pour leur gestion au sein d'un processus UNIX unique. Les caractéristiques essentielles de l'architecture de notre système sont :

- La représentation des agents sous forme de classes d'objets.
- L'existence d'un séquenceur pour gérer les agents.
- Le partage d'un ensemble de données pour permettre l'échange d'informations entre agents.

Nous présentons dans ce qui suit l'implantation de classes d'agents abstraites et héritées programmées en C++, le séquenceur, et enfin, le partage de l'environnement.

3.1.6.1 Classes d'agents

Sur le plan informatique les agents sont représentés par des classes implantées en C++ (fig. 3.9). Le modèle générique d'agent est conçu comme une classe générique. Les membres de cette classe représentent les données permettant de caractériser globalement un agent, c'est-à-dire son identifiant et son germe.

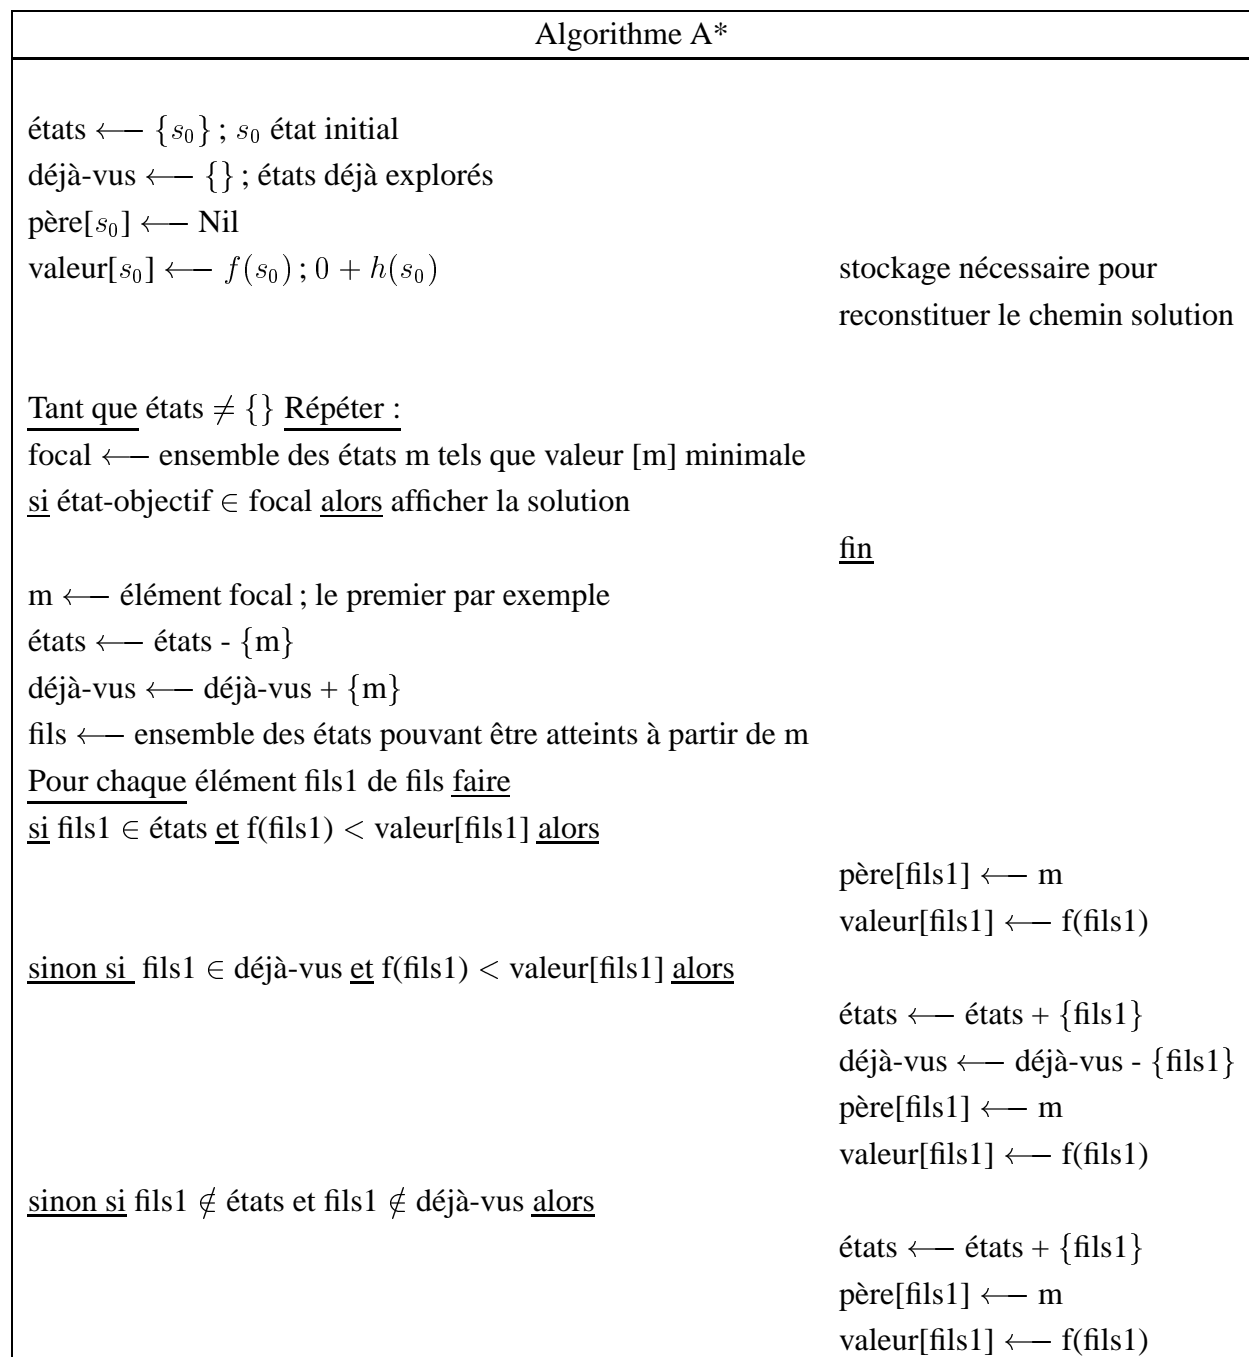


FIG. 3.8: Principe de l’algorithme A*.

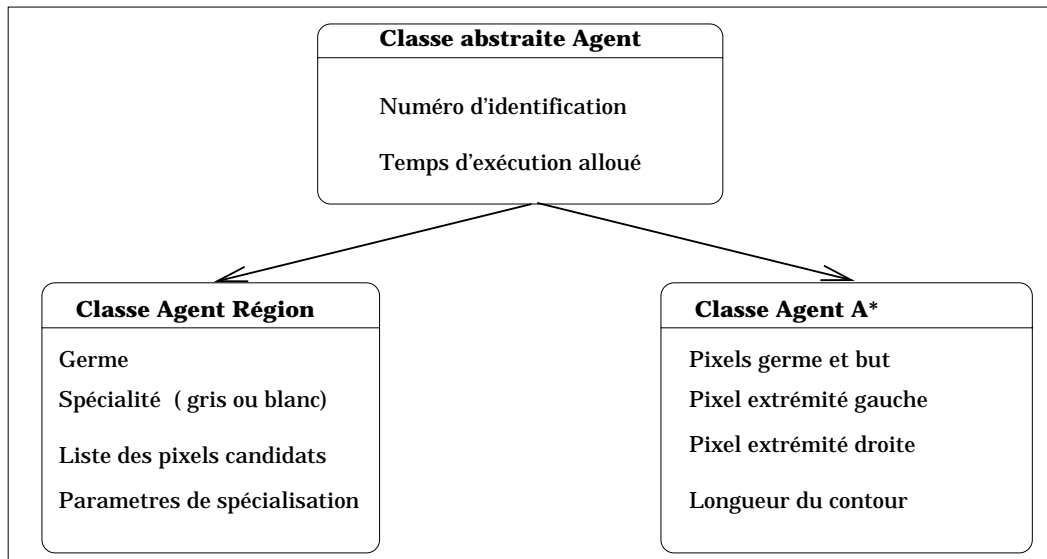


FIG. 3.9: Implantation des classes et sous-classes d'agents avec principe d'héritage.

Les agents région spécialisés sont représentés par une classe unique héritée de la classe d'agent générique. Cette classe permet de représenter la spécialité d'un agent (matière grise ou matière blanche), ainsi qu'un certain nombre de notions telles que les paramètres de spécialisation (μ_i, σ_i), la taille de la région en cours de construction, sa variance,...

Les agents contours A* sont représentés par leur germe, extrémité initiale du contour et le pixel objectif qui sera l'extrémité finale du contour. Les pixels Extrémité gauche et Extrémité droite sont utilisés pendant la construction du contour pour orienter le contour.

3.1.6.2 Séquencement des agents

Le séquenceur est l'objet informatique qui gère l'exécution des agents. Son rôle est de permettre une répartition équitable du temps machine entre les agents (fig. 3.10). L'objectif est de permettre une émergence progressive de la solution simultanément dans toutes les zones de l'image et de répartir la tâche de segmentation. Les agents partagent à tout moment l'état courant de la segmentation. Ils peuvent donc savoir, lors de l'examen d'un pixel, si celui-ci a déjà été segmenté et dans ce cas ils ne peuvent pas le ré-affecter, l'affectation d'un pixel étant définitive. Par conséquent, si les agents étaient exécutés séquentiellement, les premiers agents pourraient envahir des zones très larges de l'image et déséquilibrer le processus de segmentation.

En pratique, la tâche unitaire réalisée par un agent correspond à l'agrégation de n pixels. Cette granularité permet d'éviter la gestion d'interruptions qui apparaîtraient à des moments

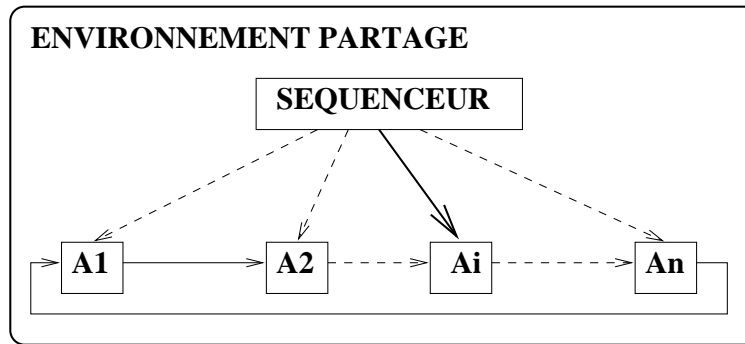


FIG. 3.10: Principe de séquençage des agents par contrôle centralisé de l’allocation des temps d’exécution.

inoportuns comme par exemple au cours de l’évaluation d’un pixel.

Les agents “actifs” sont donc introduits dans une liste selon leur ordre de création. Il n’y a pas de critère de priorité entre agents. Cela est principalement justifié par le fait qu’à chaque étape de notre processus de segmentation, le séquenceur ne gère qu’un seul type d’agents. On aurait cependant pu envisager d’introduire une notion de priorité liée par exemple à la fiabilité des échantillons prélevés dans le cas des agents régions et fondée sur les paramètres de spécialisation.

Après la génération de la liste des agents, le séquenceur permet successivement à chaque agent d’agréger $n = 100$ pixels. Le choix de ce nombre est expérimental. Il permet d’éviter un grand nombre de parcours de la liste des agents pour réaliser une segmentation complète, ce qui serait coûteux en temps, tout en conservant une simultanété d’exécution suffisante pour les agents. Un exemple d’exécution du système est présenté dans la figure (fig. 3.11), il montre la croissance simultanée des agents région dans toutes les zones de l’image.

Lorsqu’un agent a terminé son exécution, il en informe le séquenceur qui le retire de la liste des agents “actifs”. La segmentation se termine lorsqu’il n’y a plus d’agents dans la liste. Le séquenceur rend alors la main au programme principal.

3.1.6.3 Partage de données

La communication au sein d’un système multi-agents reste un problème complexe [Afia 97]. Nous n’avons pas mis en oeuvre un processus d’échange d’informations direct entre 2 agents bien que cela pourrait être utile en cas de conflit sur l’affectation d’un pixel à une région.

La solution retenue pour permettre un échange d’informations entre agents est celle d’un environnement partagé. L’intérêt de ce choix réside dans sa simplicité d’implantation ainsi que

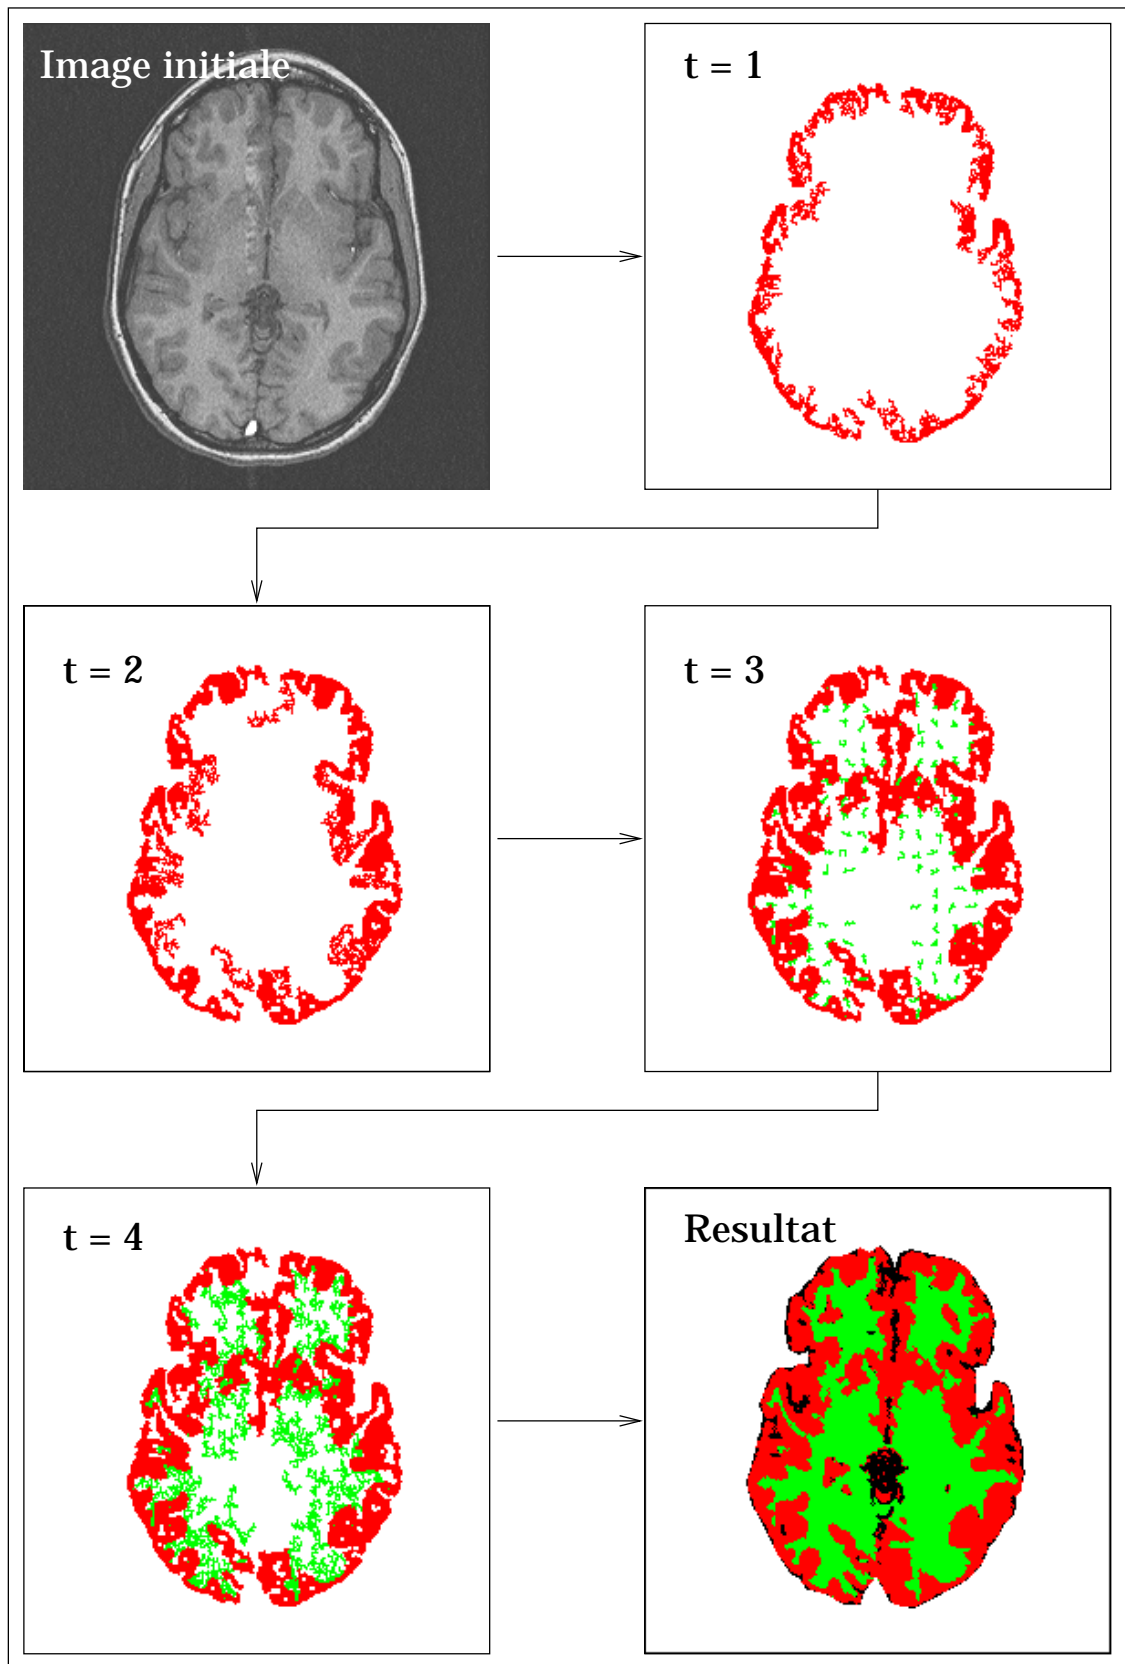


FIG. 3.11: Evolution de la segmentation par les agents régions à 4 instants successifs de l'exécution du système.

dans sa capacité à répondre à nos besoins.

En effet, l’environnement partagé sert essentiellement à la spécialisation des agents ainsi qu’à une consultation des données en cours de construction.

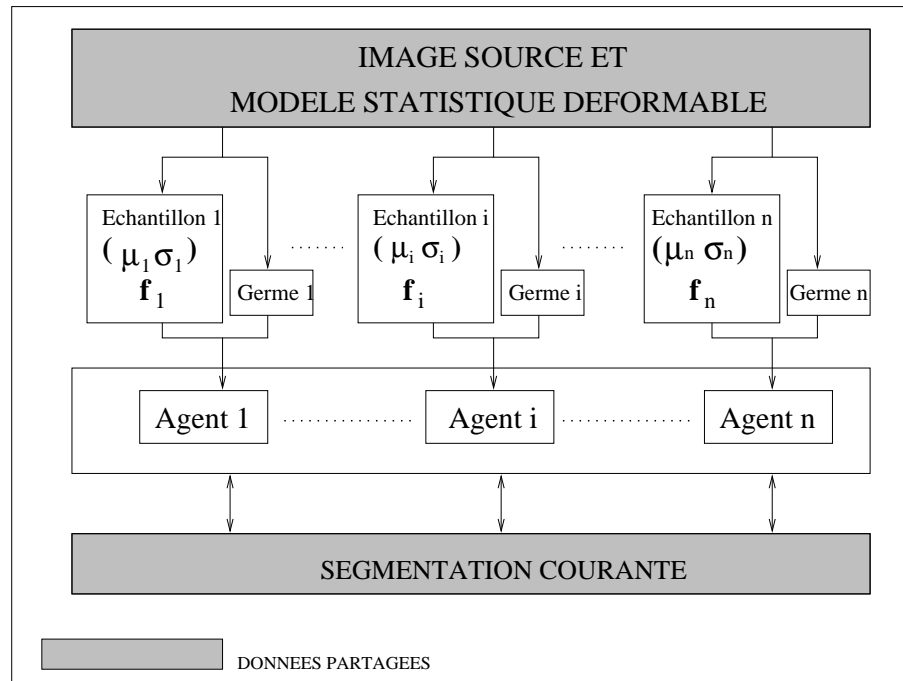


FIG. 3.12: Principe de spécialisation des agents régions dans le contexte du partage d’environnement.

Dans notre système les données partagées sont :

- L’image source
- La segmentation en cours de construction
- L’image contenant le contour trouvé par le modèle
- Le résultat de la détection des contours par le détecteur de contours.

La figure 3.12 présente le principe d’environnement partagé pour la spécialisation et l’exécution des agents de type région.

Bilan sur le module “Agents”

Nous avons présenté dans cette partie un système multi-agents pour la segmentation. Différentes classes d’agents ont été définies pour répondre à des besoins spécifiques, tels que l’adaptativité, la localisation...

Dans notre approche, les agents sont les entités de base qui permettent d’analyser les images. Ils permettent d’effectuer la segmentation en régions des principaux tissus cérébraux et également, la détection de contours lorsque cela est nécessaire.

Cependant, nous avons montré que l’utilisation isolée d’un tel système multi-agents ne pouvait pas fournir de résultats satisfaisants, et qu’il était nécessaire de contraindre les processus de localisation et de croissance des agents.

La définition d’un ensemble de contraintes ne peut se faire que par apport d’autres sources d’information indépendantes. Les modules que nous décrivons dans les parties suivantes, module “Modèle” et module “Détecteur de contours” permettent, dans un cadre coopératif, de générer des contraintes spécifiques pour les agents.

3.2 Module “Modèle”

Le modèle statistique déformable proposé par Cootes & al. [Cootes 95] est fondé sur la caractérisation des déformations d’un objet 2D grâce à l’analyse d’un ensemble d’apprentissage.

Chaque exemple de l’ensemble d’apprentissage est manuellement segmenté et utilisé pour calculer un ensemble de statistiques décrivant l’objet étudié.

Le modèle issu de l’analyse permet de décrire plus généralement l’objet étudié et de rechercher de nouvelles occurrences de cet objet dans d’autres images.

L’ensemble des logiciels permettant la construction et l’utilisation d’un tel modèle nous a été fourni par le Department of Medical Biophysics de l’université de Manchester, dans le cadre d’une collaboration européenne ALLIANCE. Notre travail a consisté à définir le contour à modéliser ainsi que l’ensemble d’apprentissage associé, à le marquer interactivement et enfin à tester sa validité. Les notions théoriques présentées dans ce chapitre sont extraites de [Cootes 95]. Des extensions 3D de ce modèle ont été proposées dans [Nikou 99].

3.2.1 Marquage et alignement des exemples

3.2.1.1 Marquage de l’ensemble d’apprentissage

La construction d’un modèle nécessite l’introduction de connaissance sur le domaine d’application. Dans le cadre des modèles statistiques déformables, la connaissance est introduite grâce au marquage, pour chaque exemple d’un ensemble d’apprentissage, d’un ensemble de points remarquables appelés aussi *landmarks*.

Etant donné un objet, il est possible de repérer un ensemble de points significatifs qui existent dans cet objet. Par exemple, dans un modèle de “main”, l’extrémité de chaque doigt ou la jonction entre deux doigts constituent un ensemble de points remarquables, identifiables dans toutes les occurrences de l’objet “main”.

A l’issue du marquage d’un exemple, l’information retenue pour la construction du modèle est de deux types :

- Une information de type **forme** constituée par la liste ordonnée des coordonnées de chaque point marqué dans l’exemple.
- Une information de type **apparence** constituée par les niveaux de gris observés autour d’un point marqué.

3.2.1.2 Apprentissage incrémental des déformations

Le marquage des exemples est un processus interactif et incrémental.

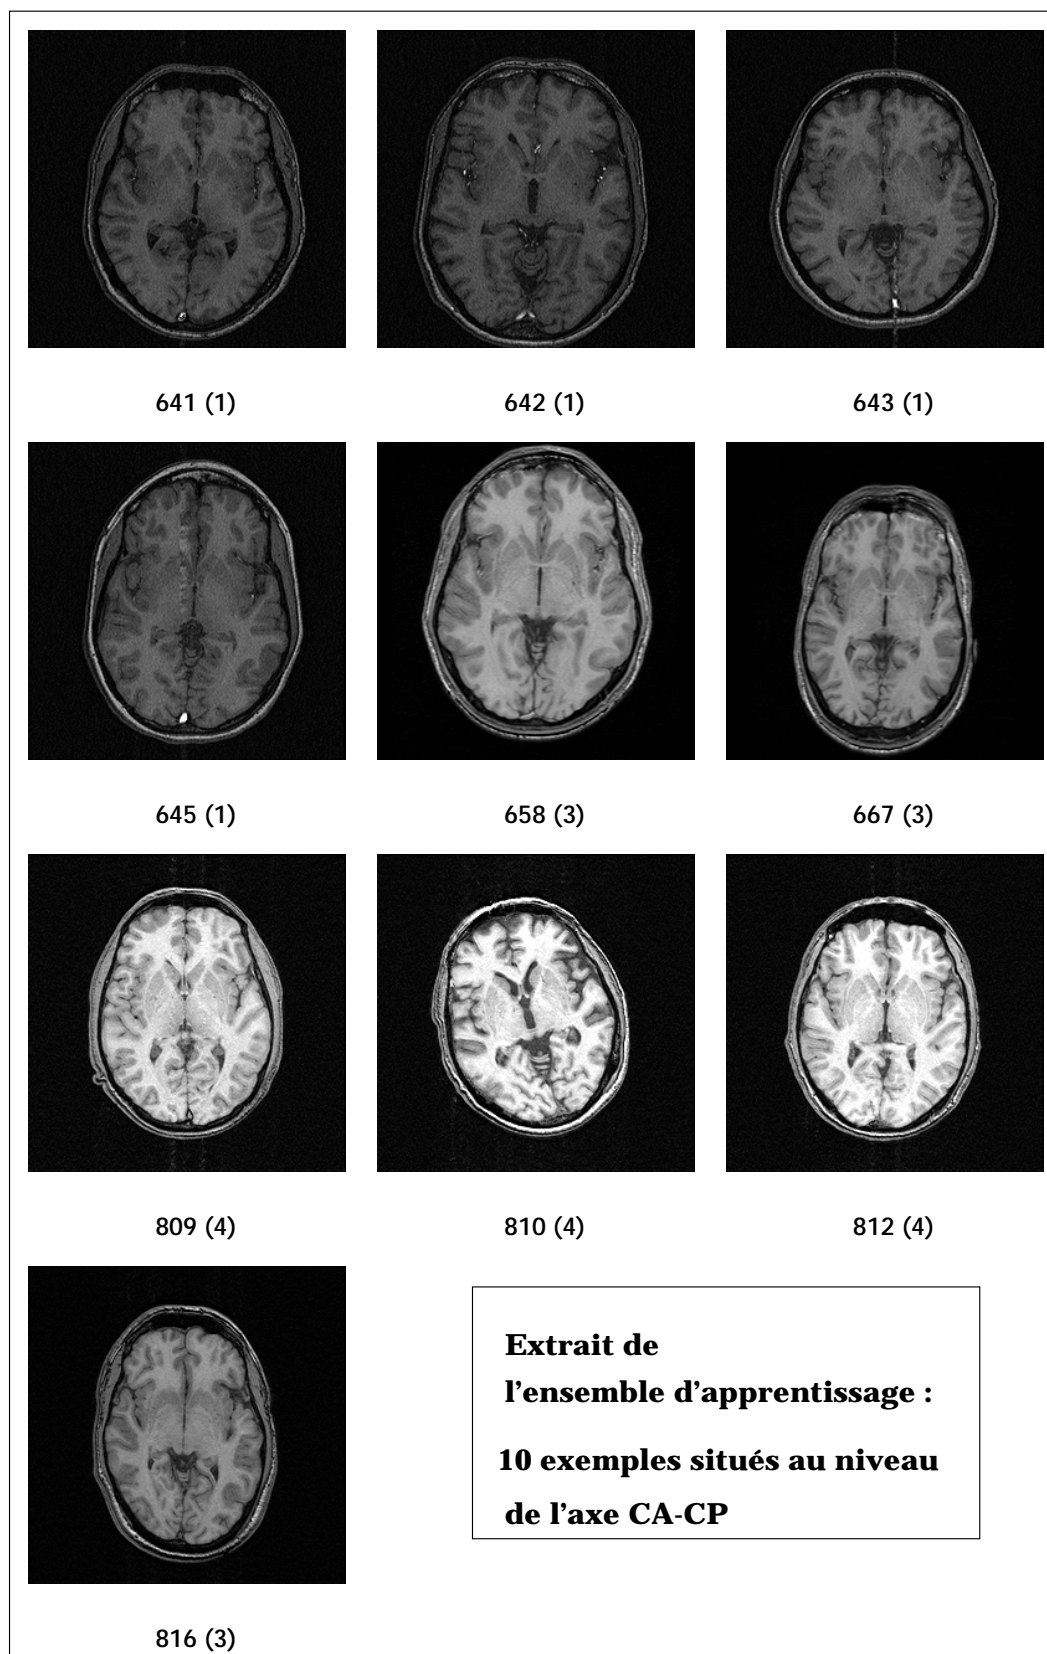


FIG. 3.13: Ensemble des images utilisées pour la construction du modèle statistique. Les numéros entre parenthèses correspondent aux séquences d'acquisition (voir 1.2.5).

Il est en effet possible de construire un modèle sur un nombre croissant d'exemples et d'utiliser le modèle construit à partir des $n - 1$ premiers exemples pour guider le marquage de l'exemple n .

Tant que n est petit ($n < 10$), des corrections manuelles sont nécessaires pour améliorer le résultat produit par le modèle encore imprécis. Au fil des apports d'exemples, le nombre des ajustements interactifs diminue et permet d'accélérer le marquage de l'ensemble d'apprentissage.

De plus, en re-calculant le modèle final sur les exemples initiaux de l'apprentissage on peut affiner le marquage et améliorer la qualité du modèle final.

3.2.1.3 Alignement de l'ensemble d'apprentissage

Afin de déduire des statistiques décrivant l'objet à modéliser il est nécessaire de générer un ensemble d'apprentissage homogène et aligné.

L'homogénéité des exemples est obtenue grâce à l'incrémentalité de l'apprentissage interactif, qui garantit que deux exemples comportent le même nombre de points décrivant les mêmes parties de l'objet (fig. 3.14).




FIG. 3.14: Exemple de points marqués sur une image de l'ensemble d'apprentissage et détail de la numérotation.

A l'issue du marquage, une procédure d'alignement permet de projeter tous les exemples dans un même repère, généralement le repère du premier exemple. On note $\mathbf{x}_i = (x_{i1}, y_{i1}, \dots, x_{in}, y_{in})$ l'exemple i en 2D. Il est représenté par les coordonnées de chacun des n points qui le composent.

La mise en correspondance de deux exemples quelconques est effectuée en recherchant une transformation optimale, combinant translation, rotation et mise à l'échelle, qui permette de passer d'un exemple à l'autre.

L'algorithme d'alignement de l'ensemble d'apprentissage est le suivant :

- Effectuer une translation, rotation et mise à l'échelle qui aligne tous les exemples sur le premier. Cela est effectué en minimisant la somme pondérée des carrés des distances entre points de même numéro par une méthode de calcul matriciel standard.
- Répéter jusqu'à convergence :
 1. calculer la forme moyenne à partir des exemples alignés
 2. normaliser l'orientation, l'échelle et l'origine de la forme moyenne à des valeurs par défaut
 3. réaligner chaque exemple avec la forme moyenne courante

La normalisation garantit la convergence de l'algorithme. Le critère d'arrêt est un seuil sur la variation des paramètres de déplacement entre deux itérations successives.

A l'issue des phases de marquage et d'alignement, l'ensemble des exemples est adapté à un traitement statistique permettant d'en extraire les principales caractéristiques. La figure 3.13 présente une partie de l'ensemble des images que nous avons utilisées pour construire un modèle de contour du cerveau au niveau de l'axe anatomique CA-CP. Au total, nous avons introduit 19 exemples issus d'individus tous distincts dans l'ensemble d'apprentissage.

3.2.2 Modélisation statistique

3.2.2.1 Calcul des modes de déformation

L'objectif de la modélisation est de permettre la mise en évidence des relations spatiales entre les différentes positions des points marqués.

Pour décrire les déformations de l'objet, on s'intéresse aux écarts à la forme moyenne \bar{x} (éq. 3.2) de cet objet. Pour un modèle comportant n points, l'ensemble des écarts dx_i (éq. 3.3) peut être projeté sur un ellipsoïde en $2n$ -D grâce à une Analyse en Composantes Principales (ACP) de leur matrice de covariance S (éq. 3.4).

Le résultat de cette projection permet de décrire, selon les axes principaux de l'ellipsoïde, les principaux modes de déformation du modèle.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.2)$$

$$dx_i = x_i - \bar{x} \quad (3.3)$$

$$S = \sum_{i=1}^N dx_i^T dx_i \quad (3.4)$$

Les modes de déformation sont décrits par les vecteurs propres normalisés p_k , associés aux valeurs propres λ_k vérifiant (3.5) :

$$Sp_k = \lambda_k p_k \quad (3.5)$$

L'intérêt d'une telle analyse est de permettre la description des déformations grâce à un nombre limité de vecteurs. En effet, la variabilité décrite par les t premiers vecteurs propres ($t \ll n$) est généralement suffisante. La figure 3.15 représente les 3 principaux modes de déformation du modèle du cerveau. La colonne du milieu représente la forme moyenne et de part et d'autre on trouve la déformation selon un mode.

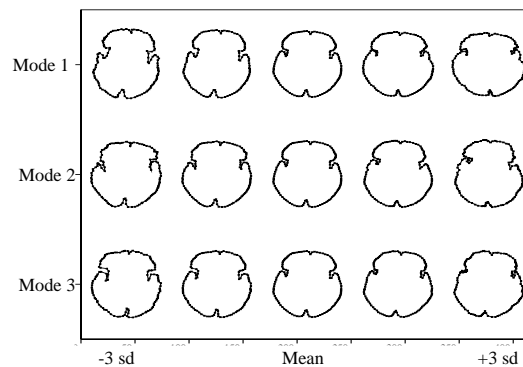


FIG. 3.15: Principaux modes de déformation du modèle. La colonne du milieu présente la forme moyenne. Les lignes représentent les déformations selon un seul mode. Le premier mode est sur la première ligne.

Les pourcentages de variabilité expliqués par les 6 premiers modes de déformation sont présentés dans le tableau 3.16. Ils montrent que 75% de la variabilité est représentée par les 3 premiers modes de déformation. Dans certains modèles, la variabilité expliquée par les 3 premiers modes de déformation peut aller jusqu'à 95%.

3.2.2.2 Génération de nouvelles formes

Grâce à l'analyse en composantes principales, de nouvelles formes peuvent être générées en ajoutant à la forme moyenne une combinaison linéaire des principaux vecteurs propres du modèle.

Mode 1	$\lambda_1 = 33.5\%$
Mode 2	$\lambda_2 = 30.5\%$
Mode 3	$\lambda_3 = 10.9\%$
Mode 4	$\lambda_4 = 7.2\%$
Mode 5	$\lambda_5 = 5.5\%$
Mode 6	$\lambda_6 = 4.9\%$

FIG. 3.16: Pourcentages de variabilité expliqués par les différents modes de déformation.

On note $\mathbf{P} = (\mathbf{p}_1, \dots, \mathbf{p}_t)$ la matrice des t premiers vecteurs propres retenus pour décrire la variabilité de l'objet étudié et $\mathbf{b} = (b_1, \dots, b_t)^T$ un vecteur de poids. Une nouvelle forme \mathbf{x} peut être obtenue par la formule (3.6).

$$\mathbf{x} = \bar{\mathbf{x}} + \mathbf{P}\mathbf{b} \quad (3.6)$$

Afin de contraindre toute nouvelle forme à rester dans les limites de variabilité observées dans l'ensemble d'apprentissage, des limites sont fixées pour les coefficients de la combinaison linéaire. Typiquement, elle sont associées aux valeurs propres par la relation (3.7).

$$-3\sqrt{\lambda_k} \leq b_k \leq +3\sqrt{\lambda_k} \quad (3.7)$$

3.2.2.3 Modélisation de l'apparence

La modélisation de l'apparence, en parallèle avec la modélisation de la forme, a principalement pour but de guider la phase de recherche d'une nouvelle occurrence de l'objet.

En effet, lors d'une recherche, il est nécessaire de définir les déplacements optimaux permettant de déformer le modèle vers un nouvel exemple. Ces déplacements sont fondés sur une corrélation entre les niveaux de gris observés dans l'image en cours d'analyse et un modèle de l'apparence attendue en chaque point de l'objet.

Nous décrivons la construction d'un tel modèle d'apparence.

Le modèle d'apparence est constitué par un ensemble de modèles locaux d'apparence calculés en chaque point du modèle et représentés par des matrices de covariance. Pour chaque point i du modèle, un rectangle de taille $n_x * n_y = n_r$ (en général 5x5 pixels), centré autour du point i , est sélectionné. Pour chaque pixel j du rectangle, on calcule le gradient g_{ij} selon la normale au contour en i et on obtient un vecteur $g_i = (g_{i1}, \dots, g_{ir})$. Ce vecteur est normalisé par la somme des normes en chaque pixel (eq. 3.8).

$$g'_i = \frac{g_i}{\sum_{j=1}^r |g_{ij}|} \quad (3.8)$$

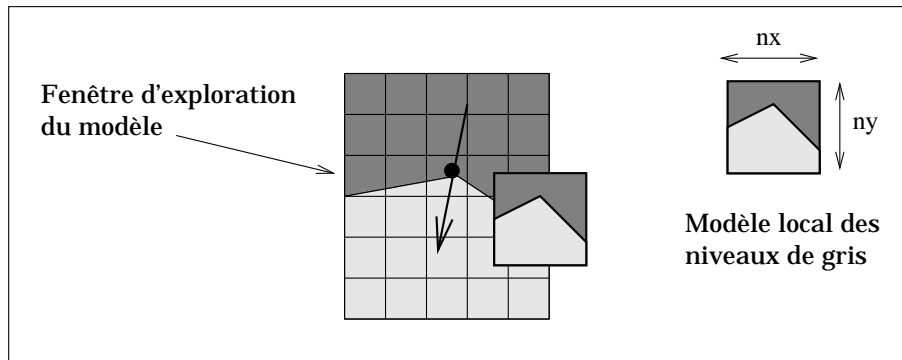


FIG. 3.17: Principe de mise en correspondance entre un modèle local d'apparence et une image.

Suivant le même principe que pour la génération du modèle de la forme, on calcule la moyenne \bar{g}_i (eq. 3.9) de tous les vecteurs g'_i puis les écarts à la moyenne δg_i (eq. 3.10). Enfin, on calcule la matrice de covariance S_{g_i} (eq.3.11) de chaque vecteur g'_i . Elle représente les relations entre les variations des niveaux de gris pour le rectangle considéré, en moyenne pour tous les exemples et servira à guider le processus de recherche.

$$\bar{g}_i = \frac{1}{N} \sum g'_i \quad (3.9)$$

$$\delta g_i = g'_i - \bar{g}_i \quad (3.10)$$

$$S_{g_i} = \delta g_i^T \delta g_i \quad (3.11)$$

La figure 3.17 présente le principe de mise en correspondance entre un modèle local d'apparence et l'image étudiée. L'optimisation mise en oeuvre lors d'une recherche prendra en compte les corrélations entre les modèles locaux et l'image pour ajuster les déformations du modèle.

3.2.3 Recherche d'un nouvel exemple

3.2.3.1 Principe de la recherche

A l'issue de la construction du modèle, l'ensemble des processus qui permettent la détection de nouveaux exemples est totalement automatique et ne requiert plus d'interaction de la part de l'utilisateur. L'objectif d'une recherche pour un nouvel exemple est de calculer les meilleurs paramètres pour la combinaison linéaire (eq. 3.12) :

$$x = \bar{x} + Pb \quad (3.12)$$

Cependant, cette recherche est aussi liée à un positionnement correct du modèle dans l'image par rapport à l'objet recherché. Il est donc nécessaire de rechercher deux ensembles de

paramètres : l’un décrivant la position globale du modèle dans l’image et l’autre décrivant les déformations internes au modèle (voir fig. 3.18).




FIG. 3.18: (a) Exemple d’une initialisation de la position du modèle. (b) Résultat de la recherche.

La recherche d’une nouvelle occurrence est donc fondée sur un processus itératif à deux composantes :

1. Calculer la meilleure transformation :
(*rotation + mise à l’échelle + translation*)
et l’appliquer au modèle. Cela permet de positionner au mieux le modèle dans l’image SANS le déformer.
2. Chercher le vecteur \mathbf{b} qui permet le meilleur ajustement du modèle par rapport à un déplacement idéal par une estimation aux moindres carrés. Cela permet d’ajuster le modèle à l’image en le déformant de manière contrainte à partir du résultat de l’étape précédente.

3.2.3.2 Formulation mathématique de la recherche

La relation qui lie les coordonnées X du modèle dans le repère image et ses coordonnées x dans le repère du modèle dépend des paramètres (s, θ, X_c) , représentant respectivement la mise à l’échelle, la rotation et l’origine du modèle (eq. 3.2.3.2). La position initiale du modèle dans l’image est définie à partir d’une estimation initiale des paramètres s et θ .

$$X = M(s, \theta)[x] + X_c$$

1. **Transformation globale :** L’objectif est de calculer la mise à jour des paramètres (s, θ, X_c) , représentée par $((1+ds), d\theta, dX_c)$. Cette mise à jour est calculée à partir des déplacements optimaux suggérés par les modèles d’apparence. En effet, pour chaque point du modèle, il est possible d’explorer un voisinage et de sélectionner le pixel où la corrélation entre le modèle d’apparence et les niveaux de gris observés est la plus forte.

Soit i un point du modèle, \bar{g}_i le modèle moyen d’apparence en ce point et S_{g_i} la matrice de covariance associée, pour tout pixel j du voisinage de i on peut calculer le vecteur d’observation g'_j normalisé et évaluer la corrélation f_j :

$$f_j = (g'_j - (\bar{g}_i))^T S_{g_i}^{-1} (g'_j - \bar{g}_i)$$

Le déplacement optimal du point i est associé au point j présentant le f_j maximal. L’objectif de l’optimisation est de calculer la transformation qui permette de mettre en correspondance tous les déplacements optimaux. Le résultat est donné par $(dX_c, (1 + ds), d\theta)$ et permet de connaître la nouvelle position globale du modèle dans l’image.

2. **Déformation du modèle :**

Après la transformation globale, les seules modifications qui peuvent permettre d’améliorer la mise en correspondance du modèle avec l’image courante concernent les déformations internes au modèle, soit le vecteur b .

Soit x l’instance courante du modèle vérifiant

$$x = \bar{x} + Pb$$

l’objectif est de trouver dx puis db vérifiant :

$$\begin{aligned} M(s(1+ds), (\theta + d\theta))[x + dx] + (X_c + dX_c) &= (X + dX) \\ \Leftrightarrow M(s(1+ds), (\theta + d\theta))[x + dx] &= (X - X_c) + (dX - dX_c) = M(s, \theta)[x] + (dX - dX_c) \\ \Leftrightarrow x + dx &= M((s(1+ds))^{-1}, -(\theta + d\theta))[M(s, \theta)[x]] + dX - dX_c \\ \Leftrightarrow dx &= M((s(1+ds))^{-1}, -(\theta + d\theta))[M(s, \theta)[x]] + dX - dX_c - x \end{aligned}$$

La relation qui lie dx à db est obtenue par :

$$x = \bar{x} + Pb \tag{3.13}$$

$$\Rightarrow x + dx \simeq \bar{x} + P(b + db) \tag{3.14}$$

$$\Rightarrow dx \simeq Pdb \tag{3.15}$$

Or

$$P^{-1} = P^T$$

d’où :

$$db = P^T dx$$

La figure 3.18 présente visuellement le principe d'une recherche où le modèle a été volontairement éloigné de la solution recherchée. Grâce à la puissance de la multi-résolution, le modèle est capable de bien se localiser dans l'image, puis, dans un second temps, de se déformer au mieux en exploitant les modèles locaux d'apparence appris pendant l'apprentissage.

3.2.3.3 Recherche en multi-résolution

Dans le but de faciliter et d'accélérer le processus de recherche lorsque la position initiale du modèle est éloignée de la solution à trouver, un principe de recherche en multi-résolution a été développé.

Ce principe est associé à la construction du modèle en multi-résolution grâce à l'utilisation de pyramides d'images.

Ainsi, pour chaque niveau de la pyramide, un modèle de forme et un modèle d'apparence sont construits. L'utilisateur n'effectue le marquage que sur le niveau de plus forte résolution et le reste du modèle est généré automatiquement.

La recherche d'une occurrence débute au niveau de résolution le plus faible et se termine au niveau de résolution le plus élevé.

Pour chaque niveau de résolution, l'algorithme de recherche décrit ci-dessus est exécuté jusqu'à convergence.

3.2.4 Aspects de validation

La validation d'un modèle est un problème difficile qui n'a pas de solution mathématique directe. En l'absence de formule d'évaluation globale, des protocoles expérimentaux peuvent être mis en oeuvre pour déterminer les principales caractéristiques du modèle.

Le principal problème à résoudre est de savoir si le nombre d'exemples introduits dans l'ensemble d'apprentissage est suffisant pour décrire la variabilité de l'objet modélisé. Deux types de tests ont été développés dans ce but : un test statique et un test avec recherche.

3.2.4.1 Test statique

L'objectif de ce test est d'estimer la capacité de déformation intrinsèque du modèle sans effectuer de processus de recherche. Ainsi, pour ajuster le modèle à un exemple à tester, seuls les paramètres b sont modifiés. Cela suppose que l'exemple est déjà positionné dans le repère du modèle.

Ce test permet de calculer l'erreur entre l'exemple dont on connaît le contour exact et la meilleure déformation possible du modèle. Le résultat est fourni sous forme d'une distance (point-à-point ou point-à-tangente).

En général, pour effectuer ce test (fig. 3.19), on construit le modèle sur l'ensemble d'apprentissage privé d'un exemple et on effectue le test sur l'exemple exclu. Cela est répété sur

rafalegermond : sm-tests brain
Performing miss-one-out experiments on 25 examples in brain.SMD
Testing : v007.a.22.brain.pts Mean Error : 2.10854
Testing : v008.a.19.brain.pts Mean Error : 1.44389
Testing : v009.a.17.brain.pts Mean Error : 0.882276
Testing : v010.a.19.brain.pts Mean Error : 0.383509
...
Testing : v027.a.24.brain.pts Mean Error : 1.67915
Testing : v028.a.21.brain.pts Mean Error : 2.35362
Testing : v030.a.11.brain.pts Mean Error : 1.22431
Measure : mean point-to-point square-distance
Mean of mean distance error : 1.41632 sd : 0.697845 (st.err : 0.139569)
Range : 0.383509 to 2.93403
Mean of worst distance error : 13.4853 sd : 12.6443 (st.err : 2.52885)
Range : 4.47656 to 67.6356
Errors measured in original (ie image, not model) co-ordinate frame

FIG. 3.19: Informations sur les erreurs fournies par le programme de test de la qualité d’un modèle.

tous les exemples de l’ensemble d’apprentissage.

Ce même test peut être utilisé pour évaluer si le nombre d’exemples introduits dans l’ensemble d’apprentissage est suffisant. Ainsi, on construit le modèle sur un nombre croissant d’exemples. Pour chaque modèle construit, on peut calculer la moyenne des distances d’erreurs et la distance d’erreur au pire. Les résultats sont visualisés sur une courbe. Lorsque le nombre d’exemples est suffisant, la mesure d’erreur se stabilise, ce qui signifie que l’ajout d’exemples n’a plus d’influence sur la qualité globale du modèle. En l’absence de validation théorique, ce test reste malgré tout très qualitatif.

3.2.4.2 Test avec recherche

Le test avec recherche fonctionne selon un principe similaire au test statique, avec l’ajout de la recherche des paramètres d’angle, d’échelle et de rotation. Ce test permet d’évaluer la capacité du modèle à se déplacer et se déformer vers l’objet recherché dans un contexte réel. La différence avec le test statique est donc l’intervention de l’information en niveaux de gris qui guide la déformation et les déplacements. En effet, dans le test statique, seule les déformations intrinsèques du modèle sont validées et il n’y a pas de lien avec les données images. Dans le

test avec recherche, le modèle est replacé dans un environnement en niveaux de gris contenant l'objet recherché.

Le test est effectué selon un principe de leave-one-out, ce qui revient à construire le modèle sur $(n-1)$ exemples et le tester sur l'exemple n . Cela est nécessaire pour pouvoir disposer d'un contour de référence pendant le test.

L'objectif est de minimiser à chaque fois l'erreur commise par le modèle. Il n'existe pas de critère absolu pour définir si l'erreur est suffisamment faible. Le contrôle du nombre d'exemples s'effectue plutôt expérimentalement (fig. 3.20). Selon l'organe modélisé le nombre d'exemples nécessaire varie généralement entre 15 et 25. Dans notre cas, nous avons retenu 15 exemples.




FIG. 3.20: Evolution des erreurs commises lors de l'ajout d'exemples dans le modèle. La référence est constituée par les images de l'ensemble d'apprentissage sur lequel le test est effectué. Axe des abscisses : Nombre d'images utilisées pour construire le modèle. Axe des ordonnées : Mesure de distance d'erreur entre le contour détecté et le contour de référence.

Bilan sur le module "Modèle"

L'approche présentée dans cette partie permet une détection très robuste de contours déformables dans une image. En particulier, la modélisation d'un contour du cerveau, à un niveau de coupe fixé, permet la détection d'un grand nombre de cerveaux dans des images très variées en termes de paramètres d'acquisition.

Dans la cadre de notre approche, le modèle permet essentiellement une isolation du cerveau par rapport au reste de l'image. Cela est intéressant pour éviter un pré-traitement, très souvent utilisé dans d'autres approches.

Cependant, l'existence de contraintes globales sur la forme du contour modélisé génère parfois quelques imprécisions sur la localisation exacte du contour et des corrections peuvent alors être envisagées. De plus, l'information modélisée est de type contour, il est donc nécessaire de la combiner avec d'autres approches pour effectuer une segmentation des tissus cérébraux.

3.3 Module “Détecteur de contours”

Nous présentons dans cette partie un module destiné à la détection de contours. Ce module sera intégré dans le cadre coopératif de notre approche.

Nous utilisons l’approche proposée dans [Chehikian 97] qui définit et met en oeuvre un nouveau type de détecteur de contours.

3.3.1 Présentation du détecteur

Le développement des détecteurs de contours classiques a été effectué à partir de la recherche de filtres optimaux pour la détection d’une marche continue ([Castan 90], [Canny 86], [Deriche 87]). Les filtres ainsi trouvés ont ensuite été directement étendus au cas discret par échantillonnage du signal.

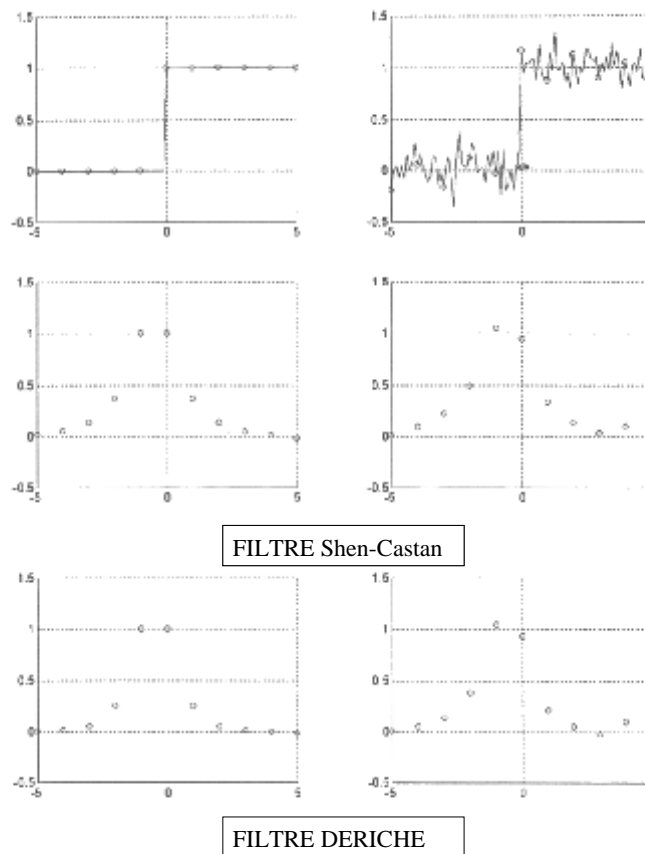


FIG. 3.21: Réponse des filtres de Chen et Castan à un contour marche discret . D’après [Chehikian 97].

La conséquence d'une telle discrétisation peut être observée dans la figure 3.21. Celle-ci montre qu'en présence de bruit il peut résulter des délocalisations des contours détectés.

L'approche proposée dans [Chehikian 97] est plus réaliste dans le sens où elle considère que le signal étudié est discret et le prend directement en compte. Ainsi, plutôt que de rechercher un filtre continu puis de le discrétiser, une interpolation du signal à l'aide de splines cubiques est effectuée et ensuite un filtre adapté est calculé. Afin de reproduire un schéma de maximum unique pour le gradient, et de passage par 0 unique pour la dérivée seconde, il est nécessaire de filtrer l'interpolation. A cet effet un filtre gaussien est utilisé (fig. 3.22).




Figure 1. First (a) and second derivative (b) of the cubic spline approximating a step edge.




Figure 2. First (a) and second derivative (b) of the cubic spline approximating a step edge smoothed by F_1 .

FIG. 3.22: . (Haut) Principe d'interpolation spline d'un contour discret et les dérivées associées. (Bas) Résultat du lissage par un filtre gaussien des approximations splines.

Le comportement d'une telle modélisation en présence de bruit est meilleur que pour les détecteurs classiques car il conserve la localisation des contours (fig. 3.23).

A partir de l'interpolation spline et de sa corrélation avec un opérateur de filtrage gaussien, un nouvel opérateur de détection de contour est calculé. Il comporte 3 paramètres pour contrôler le lissage λ , les seuils haut θ_1 et bas θ_0 de la détection. Le rôle de chacun des paramètres est détaillé comme suit :

1. Paramètre λ : C'est un paramètre de lissage dont les valeurs sont généralement comprises entre 0 et 2. Un coefficient de 0.5 aura un effet de lissage fort et un paramètre égal à 2 aura un effet de lissage modéré. Dans le cas des images cérébrales, il est nécessaire de conserver un taux de lissage relativement modéré afin de préserver la présence de nombreuses structures fines dans la détection des contours.




Figure 6 : The proposed first order filter's response to a discrete step.

FIG. 3.23: Comportement du détecteur de contour proposé par Chehikian en présence de bruit. Les contours restent correctement localisés.

L'influence du paramètre de lissage est illustrée dans la figure 3.24. Dans la suite de nos expérimentations, le paramètre λ est choisi égal à 2.

2. Un seuil bas θ_0 : Ce paramètre permet de sélectionner les pixels pour lesquels le détecteur de gradient donne une réponse supérieure à ce seuil.
3. Un seuil haut θ_1 : Ce paramètre est utilisé dans une seconde étape. Il permet de sélectionner les pixels pour lesquels le détecteur de gradient donne une réponse supérieure au seuil haut.

Pour terminer le processus de détection, un chaînage itératif est effectué, selon un principe de seuillage par hystérésis. Il consiste à positionner à la valeur de seuil haut les pixels dont le seuil est supérieur au seuil bas et qui sont voisins d'un pixel dont le gradient est supérieur au seuil haut.

3.3.2 Choix des seuils

Le processus de détection des contours est relativement peu sensible à la variation des paramètres (θ_0, θ_1) . Typiquement, des valeurs de $(6, 12)$ donnent des résultats satisfaisants pour la quasi-totalité de notre base d'images. Des exemples sont présentés figure 3.25.

Nous avons expérimenté le choix des seuils en fonction des séquences d'acquisition IRM employées. Pour les séquences présentées dans la partie 1.2.4, nous avons trouvé que les paramètres présentés dans le tableau 3.26 donnaient les meilleurs résultats. L'approche est peu sensible à la variation de ces paramètres et il est possible de choisir une valeur de compromis qui est sa-

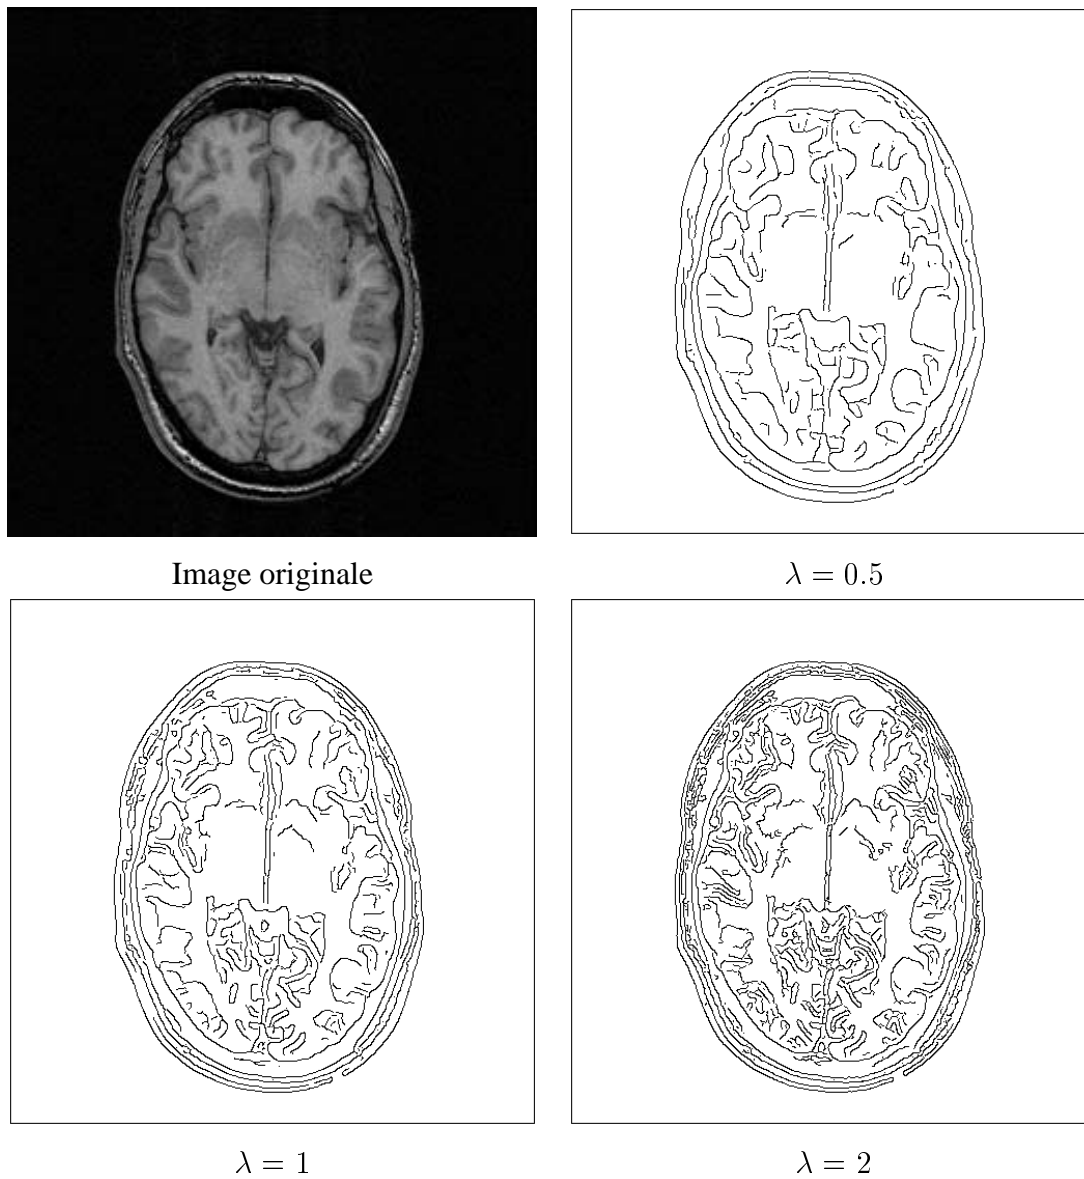


FIG. 3.24: Influence du paramètre de lissage sur le détecteur de contours.

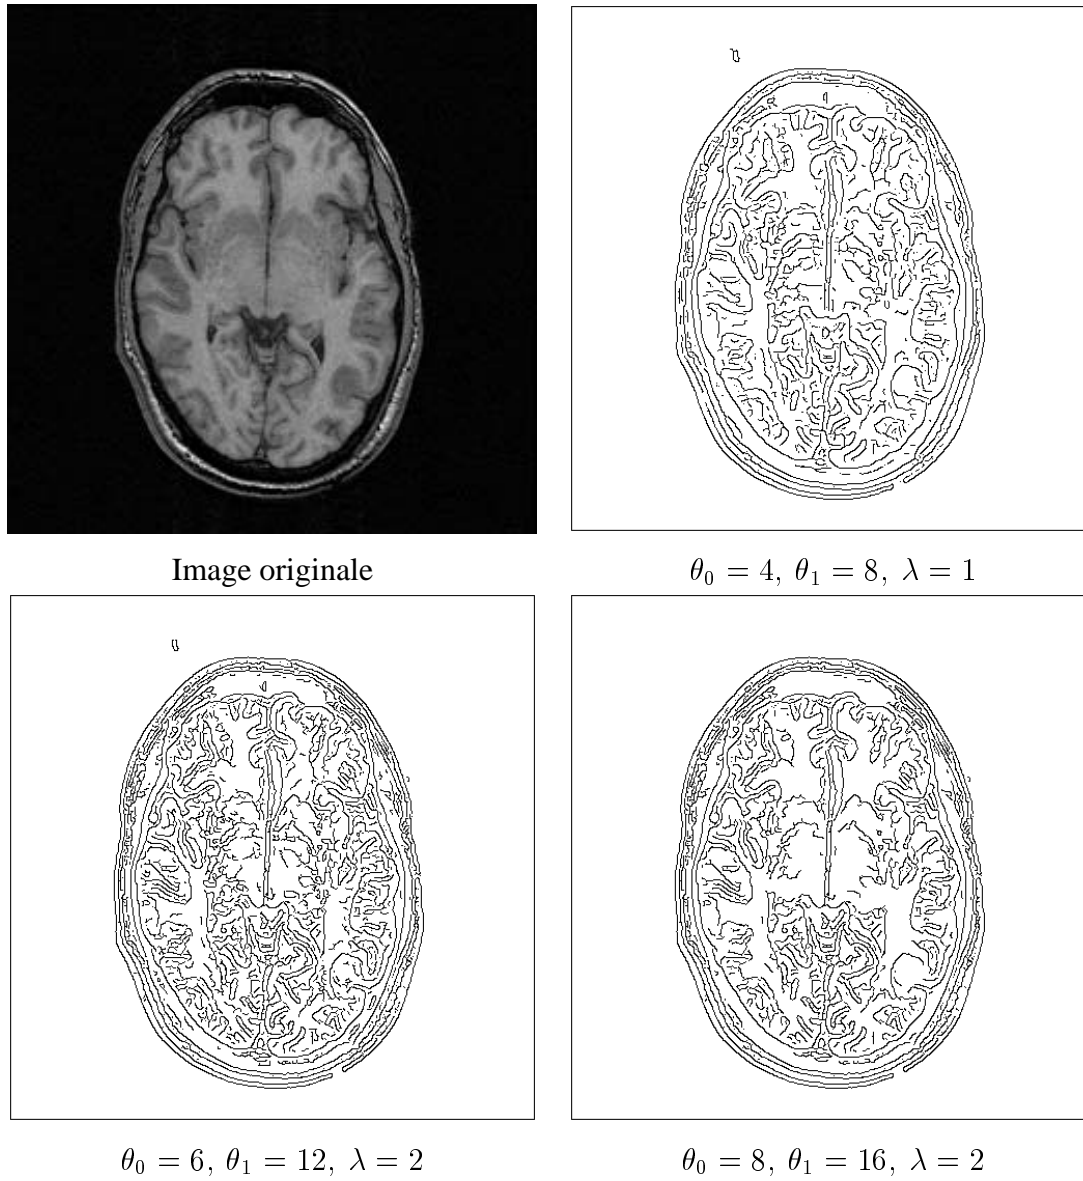


FIG. 3.25: Influence des seuils sur le détecteur de contours.

tisfaisante pour l’ensemble de nos séquences.

Ainsi, pour simplifier la suite de nos expériences, nous avons choisi de fixer les valeurs de ces paramètres à ($\theta_0 = 6$, $\theta_1 = 12$, $\lambda = 2$). Ces paramètres fournissent de bons résultats pour l’ensemble de nos séquences d’acquisition.

Séquence	λ	θ_0	θ_1
1	1.5	6	12
3	2	4	10
4	1.5	4	8

FIG. 3.26: Choix des paramètres pour le détecteur de contours en fonction de la séquence d’acquisition IRM (voir 1.2.5).

Bilan sur le module “Détecteur de contours”

Le détecteur que nous avons présenté est particulièrement adapté à l’application que nous envisageons. En effet, le principe de représentation en double résolution permet de positionner réellement les points de contours entre les pixels régions et non **sur** les bords des régions. Une conséquence directe est que la détection des structures fines, nombreuses dans le cerveau, est meilleure.

Il est toutefois nécessaire de structurer l’ensemble des contours obtenus à l’issue d’une détection. Nous verrons dans la suite de ce document comment une approche coopérative peut tirer parti des informations fournies par le détecteur de contours pour reconstruire des contours plus structurés.

Conclusion

Dans ce chapitre, nous avons présenté les différents modules qui entrent en jeu dans le fonctionnement global de notre système.

Nous avons décrit le système multi-agents ainsi que les différentes classes d'agents spécialisés qui ont été définies dans le contexte de la segmentation en IRM cérébrale.

Nous avons ensuite montré comment le modèle déformable a été construit et nous avons détaillé son principe de fonctionnement.

Finalement, nous avons présenté un détecteur de contours permettant de fournir une détection des structures fines présentes dans les images. Ce détecteur permet de localiser précisément les contours.

Dans la suite de ce document, nous montrons comment il est possible de définir des interactions entre ces modules dans le but de générer et de contraindre des agents de segmentation spécialisés. Les interactions sont décrites en termes de coopération et regroupent principalement :

- La coopération par initialisation
- La coopération par fusion d'informations
- La coopération par rétroaction

Chapitre 4

Coopération

Introduction

Dans le chapitre 2, l'étude des approches proposées pour la segmentation en IRM a fait apparaître la nécessité de la définition et de l'application d'ensembles de contraintes sur les processus de détection de régions ou de contours.

L'ensemble de notre travail sur la coopération a été guidé par la volonté de générer automatiquement des informations et des contraintes pour permettre le fonctionnement autonome de méthodes de segmentation. C'est l'aspect de complémentarité entre approches qui a permis de définir un cadre coopératif au sein duquel les informations issues de méthodes distinctes (système multi-agents, modèle déformable, détecteur de contours, présentées au chapitre 3) peuvent être combinées.

Les choix des informations à utiliser et de l'ordre des différents traitements à effectuer ont donc été guidés par les objectifs recherchés. L'aspect de disponibilité des informations a également fait partie des considérations prises en compte pour la définition de la coopération.

Parmi les caractéristiques des grandes classes d'approches que nous avons étudiées, nous nous sommes plus particulièrement intéressés aux informations manipulées ainsi qu'aux informations générées. Ainsi, nous effectuons une distinction entre la nature des informations et leur type :

1. La **nature** des informations : nous distinguons les informations non interprétées, issues de traitements de bas-niveau des données et les informations interprétées, issues de modèles (mathématiques ou symboliques) des connaissances.
2. Le **type** d'information : nous distinguons les information de type contour et les information de type région.

Dans l'état de l'art (chapitre 2) nous avons mentionné les approches procédant par classification et les approches utilisant des modèles.

Ces deux classes d'approches ont été proposées pour atteindre des objectifs distincts puisque les approches par classification produisent des segmentations en régions et les approches utilisant des modèles déformables produisent des contours. Ces approches sont donc complémentaires en terme de type d'information généré.

Un autre point de vue peut être adopté qui consiste à distinguer les approches fondées uniquement sur des informations de bas-niveau, qui ne permettent pas une interprétation simple des résultats et les approches fondées sur l'application de modèles de connaissance, qui sont nécessairement limitées par leur capacité à modéliser les structures recherchées, mais qui facilitent une interprétation directe du résultat fourni. Ces approches sont donc complémentaires du point de vue de la nature des informations manipulées.

L'ensemble des objectifs recherchés par ces différentes approches peut donc être vu sous un angle de complémentarité et nos travaux sur la coopération ont porté sur l'exploitation d'une telle complémentarité.

Nous proposons dans ce travail une solution hybride qui permet de tirer parti du traitement d'informations de bas-niveau tout en les combinant avec l'apport d'informations modélisées. Ainsi, nous exploitons des informations de type et de nature différents.

Le choix des combinaisons a été guidé par les objectifs à atteindre et a abouti à la mise en oeuvre d'une combinaison croisée des informations selon leur nature et leur type afin de réaliser deux objectifs complémentaires (voir fig. 4.1) :

1. La segmentation des tissus cérébraux , matière grise et matière blanche.
2. La détection du contour du cerveau.

Sur un plan méthodologique, la combinaison d'information a été réalisée via l'introduction de principes de coopérations entre différentes approches. Nous avons ainsi associé un modèle déformable à l'information de bas-niveau constituée par l'image source à travers un principe de *coopération par initialisation* et combiné la segmentation en régions avec un détecteur de contours à travers un principe de *coopération par fusion d'informations*.

De plus, un principe de *coopération par rétroaction* a été mis en oeuvre pour permettre un affinement de la solution proposée pour une coupe donnée ainsi que la transmission des informations entre plusieurs coupes du volume IRM.

L'intérêt des combinaisons d'informations réside dans les trois points suivants :

1. Générer des contraintes et des spécialisations pour les agents de segmentation région.

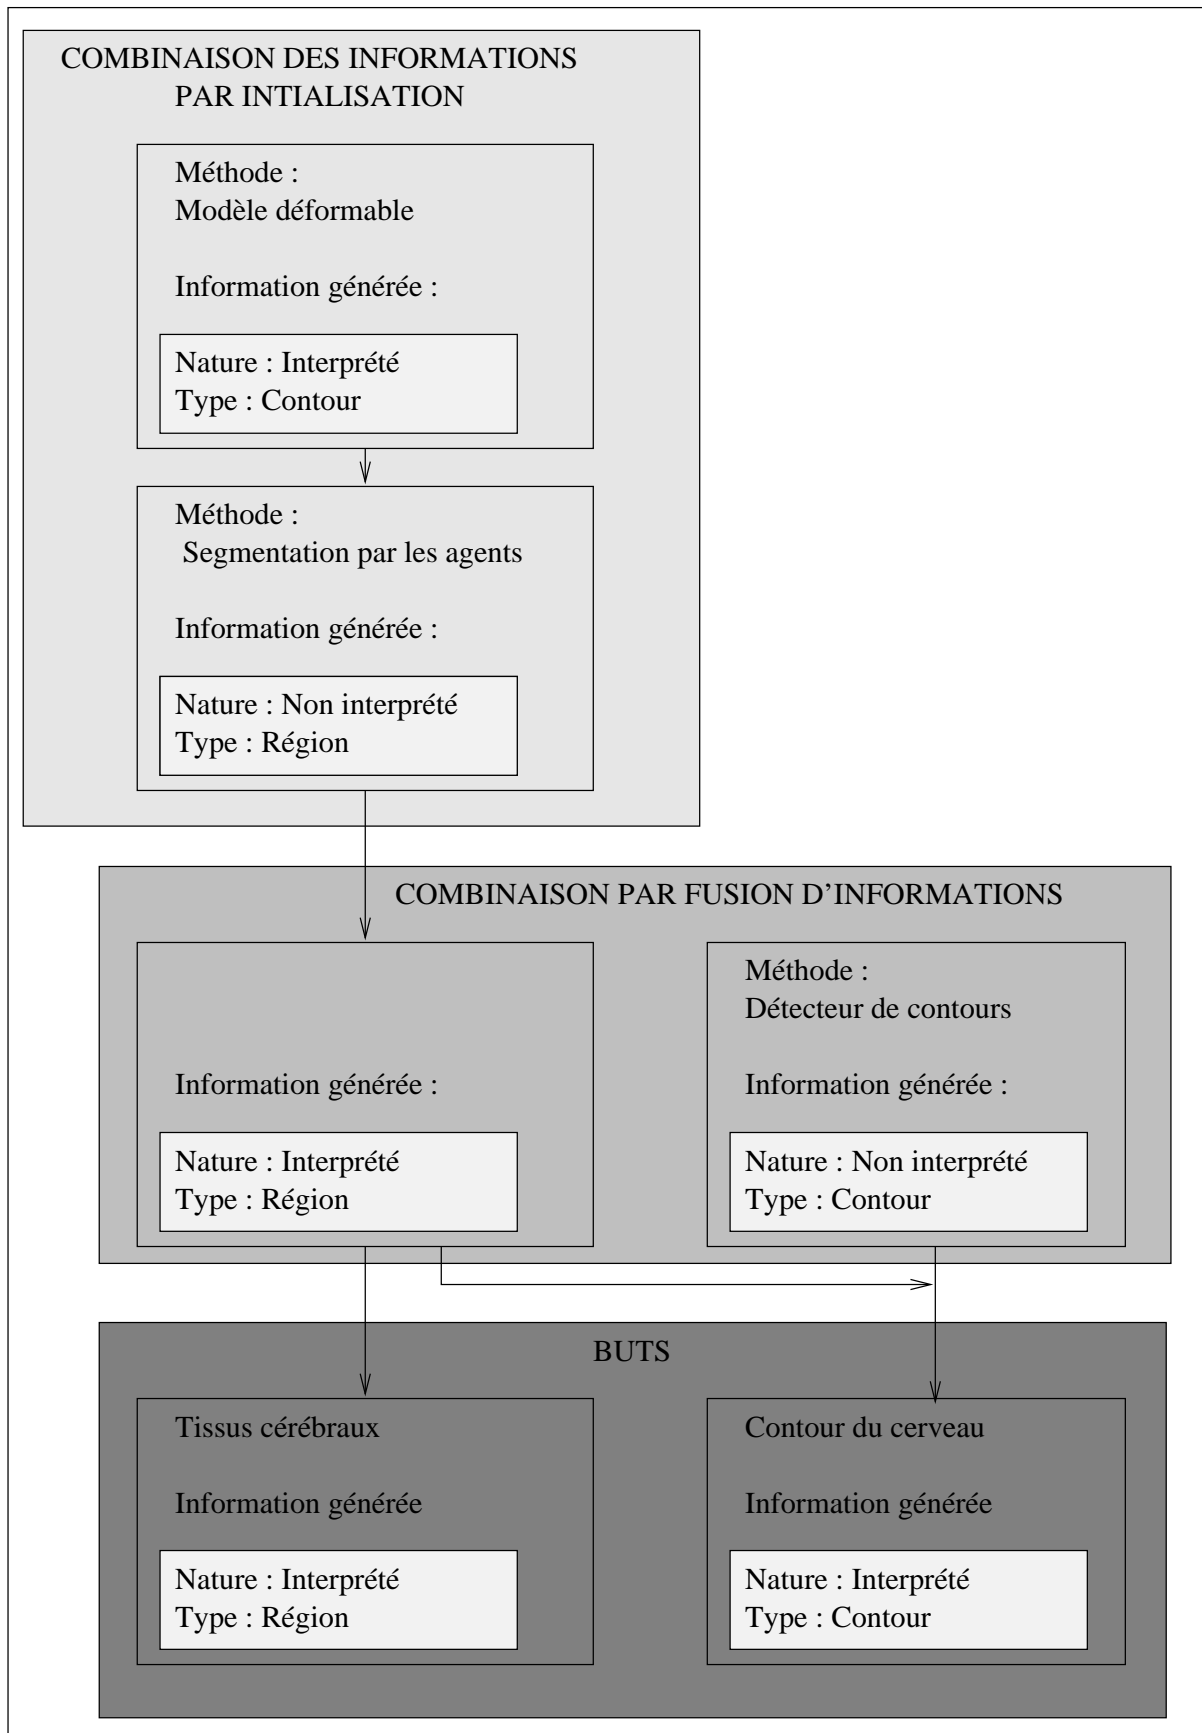


FIG. 4.1: Complémentarité de la nature et du type des informations mises en jeu dans les processus de coopération par initialisation et par fusion d'informations.

2. Générer des informations à partir de sources complémentaires pour guider des agents de détection des contours.
3. Affiner le résultat obtenu pour les régions et les contours à l'issue du processus complet de segmentation, et transmettre les informations issues du processus de segmentation à d'autres coupes du volume d'acquisition.

Dans la suite de ce chapitre, nous présentons en détail les trois principes de coopération que nous avons mis en oeuvre.

4.1 Coopération par initialisation

Dans de nombreuses approches, procédant par classification des tissus ou encore par recherche de contours déformables, la phase d'initialisation est un problème important et parfois difficile à résoudre. Plutôt que de recourir à des solutions interactives ou manuelles, il est possible de combiner plusieurs approches dans le but de réaliser l'initialisation.

C'est dans ce contexte que nous proposons de mettre en oeuvre un principe coopératif qualifié de *coopération par initialisation*. Les deux principales caractéristiques de cette approche sont les suivantes :

1. Réaliser automatiquement l'isolement du cerveau dans les images.
2. Fournir une interprétation sémantique directe de la segmentation en régions, réalisée par des agents spécialisés.

Dans le cadre de la segmentation en IRM cérébrale, l'isolement automatique du cerveau constitue très souvent une étape initiale indispensable pour la suite des traitements. Dans le cas des approches par classification, l'isolement permet en effet de réduire le nombre de classes à rechercher et donc de simplifier les calculs qui en découlent ; dans le cas des contours actifs, l'isolement fournit un contour de base à partir duquel la déformation sera initialisée.

De nombreuses approches ont été proposées pour réaliser cet isolement. On peut citer en particulier les méthodes utilisant des opérateurs de morphologie mathématique [Kapur 96],[Mangin 95], ou encore [Atkins 98], [Lee 98], [Worth 98].

Un autre problème important qui intervient dans tout processus de segmentation concerne l'interprétation des résultats. Il est en effet nécessaire d'associer automatiquement les régions détectées à une interprétation sémantique en termes de tissus cérébraux.

Nous verrons dans cette partie comment l'approche de coopération par initialisation que nous proposons permet de réaliser le double objectif d'isolement du cerveau et d'interprétation de la segmentation à travers la génération de contraintes sur des agents de type région.

4.1.1 Isolement du cerveau

Nous avons mentionné plus haut que la connaissance d'une localisation du cerveau dans l'image étudiée constitue une information importante dans le processus de segmentation. C'est principalement pour cette raison que nous avons introduit le modèle déformable dans la toute première étape de notre processus.

L'utilisation d'un modèle déformable, représentant l'enveloppe du cerveau, permet en effet de réaliser naturellement et facilement l'isolement du cerveau par rapport au reste de l'image (voir fig. 4.2). Le résultat obtenu n'est cependant pas suffisamment précis pour fournir une segmentation définitive du contour du cortex.

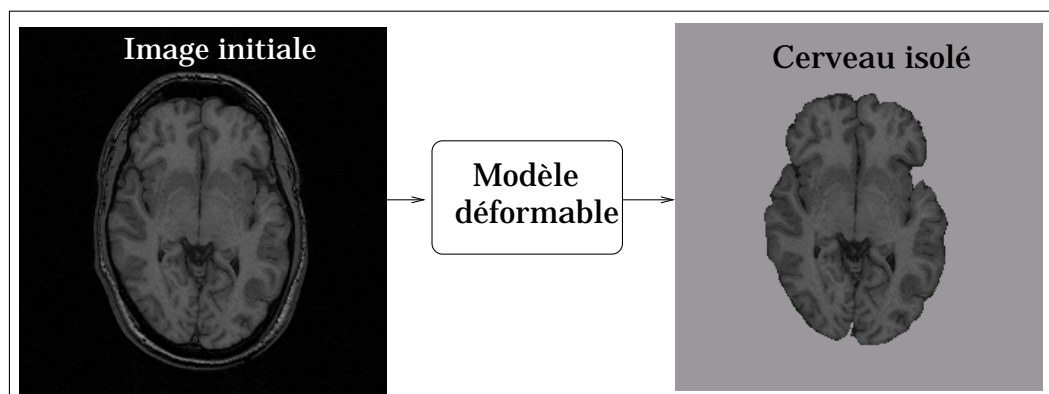


FIG. 4.2: Processus d'isolement du cerveau, par recherche du modèle déformable dans l'image originale.

A l'issue de la recherche du cerveau par le modèle déformable nous disposons donc d'un contour à partir duquel nous allons fonder notre raisonnement pour générer de nombreuses informations qui serviront à contraindre l'ensemble des agents de notre système.

Sans cette information, il serait en effet beaucoup plus difficile d'obtenir la même quantité d'information, et donc plus difficile de mettre en oeuvre un système multi-agents pour réaliser la segmentation.

L'exploitation de ce principe de génération d'informations à partir d'informations déjà connues permet de développer une approche très adaptative et automatique.

4.1.2 Localisation des tissus cérébraux

Outre l'enjeu de localisation du cerveau dans les images, il est nécessaire de pouvoir prédire approximativement mais automatiquement la localisation des zones de tissus que l'on souhaite segmenter. C'est cette localisation, fondée sur la connaissance de relations spatiales, qui permettra de réaliser l'interprétation sémantique des résultats de segmentation.

Une telle localisation ne peut pas se faire sans l'introduction de connaissance *a priori* sur l'anatomie du cerveau. Dans notre approche, nous exploitons un modèle simple de connaissance anatomique comparable à celui employé dans [Lundervold 95] et présenté dans la figure 4.3. Ce modèle précise que le liquide céphalo-rachidien entoure le cerveau et que la matière grise forme un ruban à la surface du cerveau. De plus, nous utilisons de la connaissance *a priori* sur l'ordre des niveaux de gris moyens des différents tissus. Dans nos séquences d'images, le liquide céphalo-rachidien est toujours plus foncé que la matière grise, elle-même plus foncée que la matière blanche. Cependant, dans notre implantation, la connaissance reste implicite et n'est pas modélisée explicitement comme dans le cas des approches à base de connaissance.

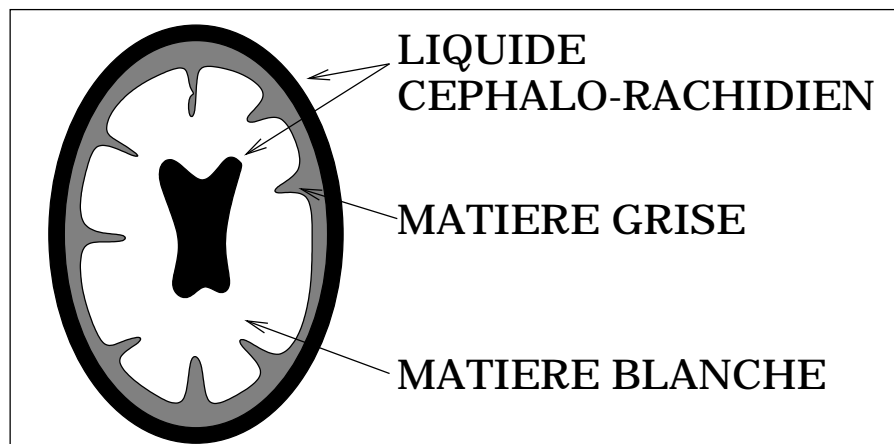


FIG. 4.3: Modèle de connaissance anatomique utilisé dans [Lundervold 95] et repris dans nos travaux.

Ce "modèle" implicite de connaissance a guidé le développement de notre processus de segmentation. En effet, nous avons montré dans la partie (3.1.2) qu'il était nécessaire de contraindre les agents de segmentation afin d'obtenir des résultats exploitables (fig. 3.3). L'introduction de connaissance anatomique dans le processus de segmentation est un moyen efficace de réaliser la génération automatique de contraintes pour les agents.

Dans le modèle d'agent que nous utilisons, deux informations essentielles permettent de contraindre le comportement d'un agent : la position de son germe ainsi que les paramètres

(μ_i, σ_i) qui décrivent sa spécialisation. Dans ce qui suit, nous montrons comment ces deux informations sont automatiquement générées à partir de l'exploitation de la connaissance *a priori* dont nous disposons sur l'anatomie du cerveau.

1. La position des germes des agents

Le principe de spécialisation que nous avons adopté pour les agents de segmentation est directement lié à la capacité à interpréter sémantiquement les résultats de la segmentation. Le bon fonctionnement des agents est conditionné par le moment et le lieu où ils sont initialisés. Ainsi, pour permettre une interprétation sémantique des résultats, il est nécessaire de positionner les germes des agents de type matière grise dans des zones de matière grise et les germes des agents de type matière blanche dans des zones de matière blanche.

En s'appuyant sur la connaissance acquise grâce à la détection du contour du cerveau par le modèle déformable ainsi que sur la connaissance des relations spatiales entre les composantes du cerveau, il est possible de localiser grossièrement la matière grise.

Celle-ci constitue en effet une bande d'épaisseur quasi-constante (2 à 3mm) à la surface du cerveau. Il est donc possible, en se déplaçant vers l'intérieur du cerveau à partir du contour détecté par le modèle déformable, de sélectionner des pixels appartenant à la matière grise et de spécialiser les agents ayant pour germes ces pixels, grâce à l'extraction d'information locale.

La matière grise apparaît donc comme le premier tissu cérébral qu'il est possible de segmenter en s'appuyant sur la donnée du contour du cerveau et en utilisant une approche de type multi-agents.

La matière blanche peut ensuite être obtenue par déduction, en positionnant les agents dans la zone restant à l'intérieur du cerveau, après segmentation de la matière grise, tout en prenant quelques précautions que nous préciserons.

L'exploration de l'image s'effectue ainsi de proche en proche, en exploitant les connaissances sur les relations spatiales pour guider l'analyse.

Ce processus se situe bien dans le cadre d'une coopération par initialisation et est résumé dans la figure 4.4.

2. La spécialisation (μ_i, σ_i) des agents

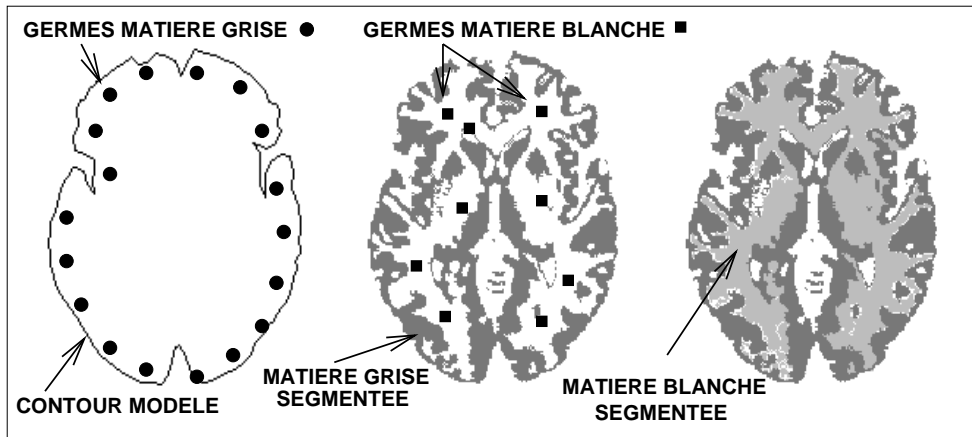


FIG. 4.4: Principe de la génération successive des agents de segmentation à partir du contour du cerveau, pour la matière grise, puis la matière blanche. D'après [Germond 99c]

La position des germes a été définie afin de permettre une spécialisation des agents. Ainsi, pour chaque type d'agent région, il est possible de définir une zone d'intérêt, à partir de laquelle un échantillon peut être sélectionné et analysé. C'est le résultat de l'analyse des échantillons qui permet de définir pour chaque agent initialisé l'ensemble de ses paramètres (μ_i, σ_i) .

Dans la suite de cette partie, nous présentons plus en détail les principes de localisation des germes et de spécialisation des agents qui ont été mis en oeuvre dans le but de segmenter la matière grise et la matière blanche.

4.1.3 Segmentation de la matière grise

4.1.3.1 Position des germes des agents

La difficulté principale liée au positionnement des germes des agents de type matière grise est de pouvoir détecter automatiquement une zone d'intérêt contenant potentiellement de la matière grise.

D'après notre modèle implicite de connaissance, nous pouvons considérer que la matière grise se trouve le long du contour interne détecté par le modèle déformable et que son épaisseur, quasi-constante, est d'environ 2 à 3mm.

Ainsi, si l'on effectue un déplacement de l'ordre de 2 pixels, c'est-à-dire 2mm pour nos images, à partir du contour détecté, vers l'intérieur du cerveau et selon une direction normale au contour, le pixel obtenu a une forte probabilité d'être de la matière grise. Dans certains cas cependant, il peut être du liquide céphalo-rachidien et nous verrons comment éliminer ces cas.

Le principe de positionnement des germes des agents de type matière grise suit ce principe de déplacement de 2 pixels, à partir du contour détecté par le modèle déformable, seule source d'information fiable et disponible à ce stade de l'exécution du système.

Ce processus de placement d'un germe est répété tous les k pixels lorsqu'on parcourt le contour issu du modèle déformable. La valeur de k a été fixée expérimentalement de manière à réaliser un compromis entre un grand nombre d'agents et un nombre insuffisant d'agents conduisant à des sous-détections de certaines zones. Typiquement $k = 5$.

Les germes de agents de type matière grise sont donc positionnés de façon systématique le long du contour du modèle (fig. 4.5).

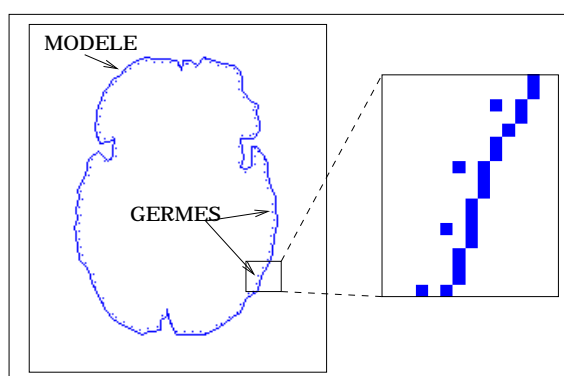


FIG. 4.5: Positionnement systématique des germes des agents de type matière grise le long du contour du modèle déformé tous les 5 pixels.

4.1.3.2 Spécialisation des agents matière grise

Afin de spécialiser les agents de type matière grise de manière automatique, nous avons cherché à extraire de l'information locale sur ce tissu. Le principe d'extraction d'information que nous avons adopté consiste à prélever des échantillons de tissu autour des germes qui ont été positionnés le long du contour issu de la déformation du modèle.

Lorsque l'extraction d'échantillons est possible, ce qui est le cas pour les agents de type matière grise grâce à notre principe de positionnement des germes, deux points essentiels restent à considérer : quelle sera la forme de l'échantillon (un rectangle ne constitue certainement pas la solution idéale), et comment sera-t-il analysé ?

1. Forme des échantillons :

En exploitant à nouveau le fait que la matière grise constitue un manteau d'épaisseur quasi-constante au bord du cerveau, nous avons choisi de faire coïncider le bord des échantillons avec le contour détecté par le modèle déformable et de fixer leur épaisseur à quelques pixels (voir fig. 4.6). De plus, chaque échantillon est centré autour du germe qui lui correspond.




FIG. 4.6: Principe de sélection d'un échantillon de tissu composé de matière grise et de liquide céphalo-rachidien au bord du cerveau.

La forme des échantillons est donc adaptée à l'information recherchée et permet d'extraire un ensemble de pixels représentant majoritairement la matière grise. Ces échantillons contiennent cependant une proportion de pixels appartenant au liquide céphalo-rachidien et il est donc nécessaire d'en tenir compte lors de leur analyse.

En pratique, l'épaisseur des échantillons est fixée à 3 pixels, et leur longueur est d'environ 100 pixels. Cela permet d'avoir des échantillons de taille suffisante pour les traitements mathématiques qui sont ensuite effectués afin de les analyser.

2. Traitement des échantillons :

Le calcul des paramètres (μ_i, σ_i) permettant de spécialiser un agent matière grise se fait par analyse de l'échantillon de tissu recueilli autour de son germe.

Afin de déduire une caractérisation locale des niveaux de gris de la matière grise, il est nécessaire d'éliminer de l'échantillon les pixels appartenant au liquide céphalo-rachidien. En utilisant une modélisation gaussienne des distributions des tissus, on peut exploiter l'algorithme Expectation/Maximisation pour rechercher 2 gaussiennes décrivant la matière

grise et le liquide céphalo-rachidien.

Les paramètres de la gaussienne ayant la moyenne la plus élevée (propriété d'acquisition de nos images : la matière grise apparaît plus claire que le liquide céphalo-rachidien) sont sélectionnés pour spécialiser l'agent AR_i .

La figure 4.7 présente des exemples d'échantillons obtenus sur une image réelle et un fantôme du Montreal Neurological Institute [Collins 98]. Les courbes comportent un histogramme décrivant les valeurs des niveaux de gris observés dans l'échantillon, ainsi que le résultat de la modélisation par 2 gaussiennes obtenues grâce à l'algorithme E/M.

4.1.3.3 Gestion des débordements

Un inconvénient souvent observé des agents fonctionnant selon un principe de croissance de région est leur tendance à déborder dans d'autres régions dès qu'il existe un *pont* entre 2 régions homogènes.

Nous avons été confrontés à des tels phénomènes de débordement et nous avons donc mis en oeuvre un ensemble de contraintes sur les agents permettant de gérer les débordements possibles des agents de segmentation vers d'autres régions.

Nous étudions ici le problème des débordements des agents de type matière grise. Pour la clarté de l'exposé, nous distinguons deux formes de débordements : ceux qui concernent une annexion de pixels appartenant à la matière blanche et ceux qui concernent une annexion de pixels appartenant à l'extérieur du cerveau.

Problèmes de débordement vers la matière blanche :

Pour les agents matière grise, nous avons résolu le problème des débordements vers la matière blanche, c'est-à-dire vers l'intérieur en supprimant certains agents pour lesquels les échantillons prélevés n'étaient pas suffisamment fiables.

Au cours de nos expériences, nous avons en effet observé des comportements d'agents de type matière grise qui menaient à une annexion de la quasi-totalité de la matière blanche. En étudiant les amplitudes des intervalles d'agrégation associés à chaque agent (éq. 3.1), il est apparu que la borne supérieure de certains des intervalles dépassait la valeur μ_{MB} du niveau de gris moyen de la matière blanche. Par conséquent, de tels agents possédaient une spécialisation (μ_i, σ_i) qui autorisait des débordements vers la matière blanche. La figure 4.8(bas) présente des cas de spécialisation pour lesquelles la borne supérieure de l'intervalle est supérieure à la moyenne de la matière blanche. Les agents correspondant à ces cas sont éliminés par le système avant le début de leur exécution.




FIG. 4.7: Modélisation par 2 gaussiennes d'un échantillon prélevé au bord du cerveau. Axe des abscisses : Valeur des niveaux de gris. Axe des ordonnées : le nombre de pixels ayant un niveau de gris donné et les modélisations gaussiennes associées. (Haut) Résultat sur une image réelle. (Bas) Résultat sur un fantôme du MNI avec 3% de bruit et 20% d'inhomogénéité.

Dans le cas présenté dans la figure 4.8(haut), on observe qu'aucun des intervalles de spécialisation des agents matière grise ne dépasse la valeur moyenne de niveau de gris de la matière blanche. Tous les agents initialisés sont donc autorisés à débiter leur exécution et on constate dans le résultat de la segmentation correspondante qu'il n'y a pas eu de phénomène de débordements.

Afin de remédier au problème, nous avons considéré que les échantillons dont l'intervalle comprenait la valeur moyenne de la matière blanche (calculée automatiquement) devaient être éliminés par manque de fiabilité selon la critère défini dans l'équation (4.1). Ce critère s'avère suffisant sans être trop restrictif par ailleurs.

$$\mu_i + \alpha\sigma_i > \mu_{MB} \quad (4.1)$$

Le traitement des agents qui ne correspondent pas aux critères de spécialisation ainsi définis est donc effectué par le système. Ainsi, l'agent est éliminé s'il ne vérifie pas les contraintes. Un autre point de vue aurait pu être de laisser l'agent découvrir sa non vérification des critères et de le laisser s'auto-éliminer, ou bien encore de mettre l'agent en concurrence avec les agents matière blanche.

Problèmes de débordement vers l'extérieur :

Pour le problème des débordements vers l'extérieur, nous avons contraint les agents à rester à l'intérieur du contour fermé détecté par le modèle déformable. Ce critère peut prêter à discussion. En effet, dans la majorité des situations, le contour du modèle est positionné sur des contours à forts gradients et donc correctement localisé. Cependant, les déformations du modèle sont soumises à un ensemble de contraintes globales. Ces contraintes peuvent parfois mener à des situations où le modèle sera décalé par rapport au contour réel, soit vers l'extérieur, soit vers l'intérieur.

- Lorsque le modèle est décalé vers l'extérieur, des agents risquent d'être initialisés dans des zones de liquide céphalo-rachidien. Cependant, d'après le principe de spécialisation, ils auront des caractéristiques représentant la matière grise. Ainsi, on se trouve dans la situation suivante :
 - Un germe ayant un niveau de gris g_i caractéristique du liquide céphalo-rachidien
 - Une spécialisation (μ_i, σ_i) représentant la matière grise et dont l'intervalle $[\mu_i - 1.5 * \sigma_i, \mu_i + 1.5 * \sigma_i]$ ne contiendra pas la valeur g_i .

Un tel agent est contraint à ne pas pouvoir agréger de pixels et est supprimé.




FIG. 4.8: Les échantillons sont représentés par le couple $(\mu_i, 1.5 * \sigma_i)$. (Haut) Aucun des échantillons de cette image ne dépasse la valeur moyenne globale de la matière blanche égale à 152 : il n'y a pas de débordements d'agents de type matière grise. (Bas) Certains échantillons dépassent la valeur moyenne de la matière blanche égale à 72 et sont donc éliminés.

Ce cas n'a en pratique jamais été observé dans nos images, le modèle ayant plutôt tendance à être légèrement en dedans du contour réel qu'en dehors.

- Lorsque le modèle est décalé vers l'intérieur, le problème n'est plus lié à la génération d'agents ayant de mauvaises caractéristiques, mais à la limitation artificielle de la croissance d'agents de type matière grise.

Etant donné la nécessité de contraindre le débordement des agents vers l'extérieur, il nous semble plus utile de contraindre la croissance que de laisser *fuir* certains agents. La solution que nous avons envisagée va dans le sens de corrections à apporter le cas échéant. Deux solutions nous semblent possibles pour résoudre ce problème :

1. Corriger localement les régions situées le long du contour du modèle en intégrant de la connaissance sur la localisation réelle du contour correspondant. Ce principe de correction relève plutôt d'un processus de fusion d'informations complémentaires.
2. Effectuer une modification du contour du modèle, en accord avec des informations locales, pour s'affranchir des contraintes globales sur les déformations. Puis itérer sur le processus complet de segmentation à partir du contour déformé et localement modifié. Ce principe de correction relève donc plutôt d'un processus de rétroaction.

Dans la suite de ce travail, nous avons retenu le second moyen de correction qui sera détaillé dans la partie 4.3.

4.1.3.4 Intérêt du processus de spécialisation

Le principe de spécialisation que nous avons mis en oeuvre pour contraindre les agents de type matière grise permet de prendre en compte, directement dans le processus de segmentation, l'existence d'inhomogénéités prouvée par ailleurs [Meyer 95], [Sled 98].

Nous avons pu, à l'issue de la spécialisation des agents de type matière grise, confirmer que ces inhomogénéités existent et les visualiser. La figure 4.9 présente les valeurs moyennes μ_i obtenues le long du cortex sur différentes images et pour des séquences d'acquisition différentes. On observe que les variations d'intensité de la matière grise se situent à deux niveaux : dans une même image d'une part, et entre deux images distinctes d'autre part. Notre approche permet donc une adaptativité inter et intra-individus automatique aux variations d'intensité.

L'intérêt du processus de spécialisation que nous avons présenté dans cette partie est de supprimer la nécessité d'un *a priori* sur les valeurs moyennes des tissus à segmenter et de permettre l'utilisation de valeurs calculées automatiquement et localement pour prendre en compte les inhomogénéités. L'approche que nous avons mise en oeuvre est donc très adaptative en deux sens :




FIG. 4.9: Axe des abscisses : Abscisse curviligne le long du contour du modèle. Ordonnées : Valeur moyenne de la matière grise pour l'échantillon correspondant au point du contour en abscisses. (Haut) Variations des valeurs moyennes des échantillons de matière grise pour des séquences d'acquisition différentes. (Bas) Variations des valeurs moyennes des échantillons de matière grise pour la même séquence d'acquisition (séquence 1, voir 1.2.5) sur des sujets différents.

- Adaptativité aux variations locales d'intensité dans la matière grise. En général, dans les images étudiées, la variation de la moyenne de la matière grise calculée sur des échantillons est d'environ 10%.
- Adaptativité aux variations entre images issues de sujets différents ou même entre images dont les modalités d'acquisition sont différentes.

4.1.4 Segmentation de la matière blanche

4.1.4.1 Position des germes des agents

De même que dans le cas du positionnement des germes des agents de type matière grise, il est nécessaire de positionner les germes des agents de type matière blanche dans des zones où l'on peut prédire *a priori* que le tissu présent est de la matière blanche.

Le principe de segmentation que nous avons adopté, qui consiste à segmenter successivement la matière grise puis la matière blanche, nous permet de déduire automatiquement une zone d'intérêt pour la recherche de la matière blanche.

Ainsi, la zone d'intérêt que nous considérons est située à l'intérieur du contour du modèle déformé et masquée par les pixels déjà étiquetés comme matière grise.

Le principe de positionnement adopté pour les germes est de couvrir systématiquement la zone d'intérêt. Ainsi, un germe est placé tous les l pixels selon l'axe de abscisses, et tous les l pixels selon l'axe de ordonnées. L'utilisation d'un schéma de type maillage régulier permet d'éviter l'"oubli" de certaines zones, d'être rapide et systématique. Lorsqu'un pixel du maillage coïncide avec un pixel étiqueté comme matière grise, il n'est pas associé à un germe.

En pratique, nous avons fixé $l = 10$, et le nombre moyen d'agents initialisés est de 90. Le but est là encore de réaliser un compromis entre trop d'agents dont certains seraient inutiles et pas assez d'agents ce qui pourrait conduire à une sous-segmentation de certaines zones.

Il faut cependant éviter certains pixels pour les germes. En effet, dans la zone du cerveau restant après segmentation de la matière grise il reste des pixels décrivant de la matière blanche mais aussi des pixels appartenant au liquide céphalo-rachidien ou aux noyaux gris centraux. Il est donc nécessaire de définir un critère permettant l'élimination automatique de ces pixels.

Ce critère est défini à partir de la connaissance de la moyenne μ_{MG} et de la variance σ_{MG} de l'ensemble des pixels segmentés en tant que matière grise. Ces deux valeurs permettent de définir un seuil au-dessous duquel les pixels sélectionnés ne pourront être considérés comme germes d'agents matière blanche. En pratique, la valeur $\mu_{MG} + 1.5\sigma_{MG}$ est utilisée.

Remarque :

Nous avons auparavant testé un autre principe de positionnement qui consistait à positionner un nombre fixé à l'avance d'agents de manière à ce qu'ils vérifient un critère d'éloignement. Les calculs associés à un tel critère étaient très lents en raison de la complexité de la frontière de la matière grise. De plus, si un nombre insuffisant d'agents était sélectionné, certaines zones de l'image pouvaient être manquées.

Ce principe a donc été abandonné au profit d'un positionnement systématique.

4.1.4.2 Spécialisation des agents matière blanche

L'extraction d'information dans le but de spécialiser les agents de type matière blanche est plus simple que dans le cas des agents de type matière grise. En effet, la matière blanche couvre une surface plus vaste que la matière grise et il est donc possible de simplifier la forme des échantillons qui sont associés aux germes. De plus le traitement des informations est également plus facile grâce à l'introduction de contraintes sur la sélection des pixels pour les échantillons.

Nous précisons ci-dessous la forme et le traitement des échantillons utilisés pour spécialiser les agents de type matière blanche.

1. Forme des échantillons :

La forme des échantillons que nous avons retenue pour les agents de type matière blanche est une fenêtre centrée autour du germe correspondant et de taille 9x9 pixels.

L'intérêt d'un tel choix est sa simplicité. L'inconvénient est qu'il nécessite de prendre un certain nombre de précautions pour éviter de sélectionner dans les échantillons des pixels qui ne représentent pas la matière blanche.

Nous précisons ci-dessous les différentes contraintes que nous avons introduites pour supprimer des fenêtres centrées autour des germes, les pixels non représentatifs du tissu étudié.

– Contrainte liée à l'existence de liquide céphalo-rachidien :

Il est nécessaire, afin de ne pas fausser les statistiques permettant de spécialiser les agents matière blanche, de supprimer des échantillons les pixels représentant du liquide céphalo-rachidien. Cette suppression est possible en adoptant un critère de seuillage. Afin de déterminer ce seuil, nous calculons pour l'intérieur du cerveau une modélisation gaussienne en 3 classes (liquide céphalo-rachidien, matière grise et matière blanche). Cette modélisation, obtenue par Estimation/Maximisation, fournit

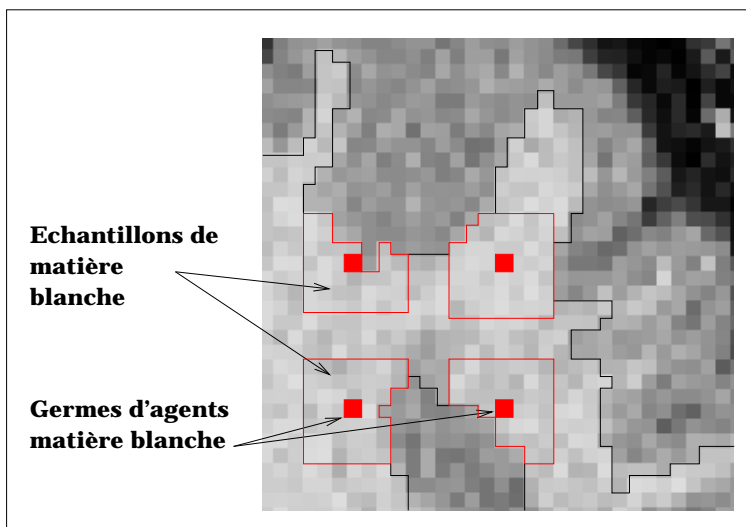


FIG. 4.10: Principe de sélection des échantillons de matière blanche.

entre autres la moyenne de la distribution représentant la matière grise. C'est cette valeur que nous adoptons comme seuil pour éliminer le liquide céphalo-rachidien des échantillons.

– Contrainte liée à proximité de la matière grise :

Etant donné le positionnement systématique des germes pour les agents de type matière blanche, il est possible que les fenêtres associées contiennent des pixels décrivant de la matière grise.

De tels pixels, déjà segmentés, sont directement éliminés des échantillons.

– Contrainte liée aux noyaux gris centraux :

La difficulté liée à la présence des noyaux gris centraux est de ne pas autoriser les agents matière blanche à segmenter ces structures internes.

Nous avons mis en oeuvre un renforcement des contraintes sur les agents de type matière blanche pour éviter les erreurs de classification potentiellement liées à ce problème.

A l'issue de la segmentation de la matière grise, il est possible de recalculer globalement la moyenne μ_{MG} et la variance σ_{MG} de ce tissu en prenant pour échantillon les pixels segmentés par les agents matière grise. La valeur $(\mu_{MG} + 1.5\sigma_{MG})$ constitue un seuil au-dessous duquel les agents matière blanche ne devraient pas pouvoir agréger de pixels. Ainsi, lors du processus de spécialisation des agents matière

blanche, les échantillons pour lesquels la valeur $(\mu_i - 1.5\sigma_i)$ est inférieure au seuil fixé précédemment sont rejetés.

Le but essentiel de la contrainte définie ci-dessus est d'éviter l'affectation de pixels correspondant à des structures internes de la matière grise, à des agents de type matière blanche.

2. Traitement des échantillons :

Le processus de traitement des échantillons que nous avons adopté est un calcul direct de la moyenne et de la variance des niveaux de gris des pixels sélectionnés. Les deux valeurs obtenues pour chaque échantillon constituent un couple (μ_i, σ_i) associé à l'agent AR_i .

Il est possible d'utiliser ce principe simple car la sélection des pixels a été soumise à un ensemble de contraintes qui permettent de supprimer les échantillons non représentatifs de la matière blanche.

La figure 4.10 montre l'allure d'échantillons pour des germes situés proche de la frontière matière grise/matière blanche. Les pixels restants de cette fenêtre constituent l'échantillon sur lequel on calcule la moyenne et la variance.

Exemples de valeurs pour les paramètres (μ_i, σ_i) :

La figure 4.11 présente les spécialisations obtenues pour les agents de type matière blanche dans 4 images différentes. Chaque nuage de points correspond à une image.

En abscisses, la valeur moyenne μ_i de chaque agent matière blanche est représenté et σ_i , sa variance est représentée sur l'axe des ordonnées.

Cette représentation n'a pas pour but de chercher à établir une relation entre ces deux informations mais plutôt de permettre leur visualisation simultanée afin de pouvoir comparer les spécialisations d'agents pour une même image et entre images différentes.

L'écart observé entre les nuages selon l'axe des abscisses correspond à des différences de séquences d'acquisition des IRM. Ainsi, le nuage 'statsMB643' est issu d'une image de la séquence 1, les nuages 'statsMB667' et 'statsMB670' correspondent à la séquence 3 (voir 1.2.5) et 'statsMBph3' correspond à l'image simulée Brain132 qui sera décrite dans le chapitre 5.

La variance est inférieure à 12 niveaux de gris, ce qui est plus homogène que pour les agents de type matière grise pour lesquels cette valeur est proche de 15.

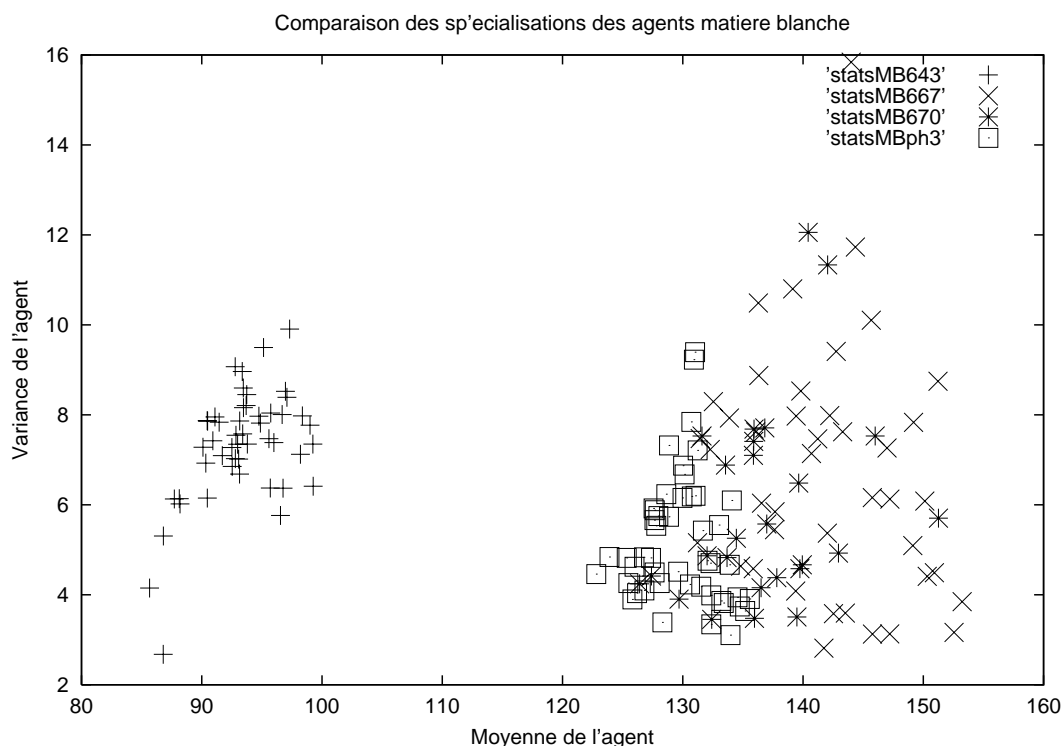


FIG. 4.11: Valeurs des moyennes (en abscisses) et des variances (en ordonnées) des agents de type matière blanche.

Bilan sur la coopération par initialisation

Dans cette partie nous avons montré comment il est possible d'exploiter la coopération par initialisation pour réaliser la segmentation.

L'intérêt de cette coopération réside essentiellement dans les deux points suivants : l'exploitation de connaissance *a priori* et la sélection d'échantillons de tissu.

Le premier point consiste à tirer parti du résultat fourni par le modèle déformable et de connaissances anatomiques pour positionner un ensemble de germes d'agents de type matière grise.

Sans la connaissance apportée par le modèle déformable, il serait en effet impossible de fixer *a priori* les positions des germes, à moins de savoir à l'avance quels niveaux de gris sont recherchés, ce qui suppose le problème résolu.

La connaissance *a priori* sur l'anatomie du cerveau et le résultat de la segmentation de la matière grise sont utilisés pour positionner les agents de type matière blanche dans les zones restant à segmenter à l'issue de la segmentation de la matière grise.

On pourrait discuter l'ordre de la segmentation des tissus : pourquoi en effet, ne pas seg-

menter d'abord la matière blanche réputée plus homogène [Teo 97], pour ensuite segmenter la matière grise, moins homogène ?

Nous avons envisagé cette approche, mais il nous a paru difficile d'extraire, via un modèle déformable ou non, des informations sur la localisation de la matière blanche dans les images.

En effet, dans un contexte de recherche de modèle déformable, la modélisation de l'interface entre matière blanche et matière grise n'est pas réalisable à cause de variabilités inter-individuelles trop importantes.

Il nous a donc paru plus réaliste de se fonder sur un modèle "stable" de contour, même si cela implique de débiter le processus de segmentation par le tissu le plus difficile.

Le second point d'intérêt de notre processus de coopération par initialisation est qu'il permet aux agents de se spécialiser localement et de manière complètement automatique.

Le principe de l'extraction d'échantillons, selon des critères précis, et détaillés dans cette partie, permet de prendre en compte les inhomogénéités des niveaux de gris des tissus.

En ce sens, nous pouvons dire que l'approche est très adaptative et qu'aucune information *a priori* n'est requise pour les niveaux de gris.

La mise en oeuvre de la coopération par initialisation nous a permis de produire une segmentation interprétée des tissus cérébraux à partir d'un système multi-agents ne permettant pas *a priori* de fournir des interprétations sémantiques des régions détectées.

La combinaison des notions d'apprentissage et d'adaptativité caractérise bien le principe de coopération que nous avons développé dans cette partie.

4.2 Coopération par fusion

L'utilisation d'un modèle déformable du contour du cerveau permet d'obtenir une information très robuste sur la position du cerveau dans les images étudiées. C'est à partir de la localisation automatique de ce contour que la génération et la spécialisation d'un ensemble d'agents de type matière grise puis de type matière blanche est réalisée.

Le contour détecté permet en outre de fixer une limite spatiale à la croissance des agents région pour éviter des débordements vers des zones situées hors du cerveau.

Cependant, le modèle déformable reste soumis à un ensemble de contraintes globales et ne permet pas la modélisation, ni la détection de structures trop variables comme les sillons.

Par conséquent, si l'on cherche à obtenir plus de détails sur le contour réel du cerveau étudié, il est nécessaire d'envisager des modifications du contour détecté par le modèle déformable.

Plusieurs approches peuvent être envisagées pour réaliser la modification partielle ou complète du contour détecté par le modèle déformable. Ainsi, il est possible d'envisager l'utilisation de contours actifs et de se servir du résultat fourni par le modèle déformable pour les initialiser. Une approche de ce type a été proposée dans [Fadili 98].

Un inconvénient de ce type d'approches est qu'il exploite un principe de minimisation d'énergie globale et que par conséquent son comportement est proche de celui du modèle déformable que nous utilisons. De plus, les déformations des contours actifs sont soumises à des contraintes de rigidité peu adaptées au problème de la détection d'un contour convolué.

Une autre approche possible, plus en accord avec notre stratégie multi-agents, serait d'utiliser des agents contours procédant par agrégation de pixels pour retracer le contour du cerveau. De tels contours présentent cependant l'inconvénient de ne pas garantir la topologie.

En effet, un aspect important de la modification du contour détecté par le modèle concerne la conservation de la topologie qu'il décrit. Cette topologie de contour fermé est une information précieuse qu'il n'est donc pas souhaitable de perdre.

Or les agents contours ne sont caractérisés que par leur pixel germe et il est impossible de fixer à l'avance les pixels qui constitueront leur extrémité finale.

Pour pallier ce problème de topologie, nous avons adopté une approche issue de la programmation dynamique. Dans ce type de programmation, il est en effet possible de fixer à l'avance deux pixels qui constitueront les extrémités du contour recherché et ensuite de déterminer le chemin optimal qui les relie, à l'aide d'une fonction de coût.

Dans ce contexte, il nous est apparu que l'on pouvait envisager de générer des agents de type "A*" caractérisés par leurs extrémités ainsi que par une fonction de coût. De tels agents doivent

permettre des modifications du contour détecté par le modèle, dans un contexte d'optimisation non global, tout en assurant une conservation de la topologie initiale.

Ainsi, nous avons défini un nouveau type d'agents spécialisés, fondés sur la programmation dynamique, qui seront utilisés pour modifier le contour du modèle. Le choix des extrémités de ces agents sera déterminé à partir de la position du modèle.

L'enjeu essentiel à ce stade consiste alors à définir une ou des fonctions de coût qui permettent d'atteindre un objectif. C'est dans ce contexte que nous envisageons de fusionner des sources d'information pour guider les agents A^* vers la solution recherchée, la fusion d'informations servant de base à la définition d'une fonction de coût adaptée.

L'état de l'art sur la programmation dynamique et ses applications pour la détection de contours est présenté en annexe. Les articles qui y sont présentés ont inspiré le développement d'une classe d'agents spécialisés.

Dans cette partie, nous présentons les sources d'information que nous utilisons et le cadre de fusion adopté. Enfin nous montrons les fonctions de coût obtenues et des exemples de détection de contours.

4.2.1 Sources d'information

4.2.1.1 Difficulté d'exploiter des informations de bas-niveau.

Les approches présentées en annexe sont toutes fondées sur l'exploitation d'informations de type bas-niveau. En effet, les fonctions de coût décrites utilisent essentiellement les niveaux de gris des images, le gradient ou encore la variance.

Dans le cadre de nos travaux nous avons constaté expérimentalement que l'exploitation de ce type d'informations était difficile. La figure 4.12 présente deux images en niveaux de gris, issues de séquences d'acquisition différentes et pour lesquelles on a calculé les images correspondantes de gradient et de variance. Ces images sont notées Source1 et Source2 et seront utilisées pour illustrer la suite de ce chapitre.

On constate que l'information recherchée est présente mais confuse et par conséquent difficile à extraire.

Dans le cadre de la détection du contour du cerveau par exemple, l'existence de contours proches du cerveau tels que les contours des méninges ou du crâne peuvent être sources de confusion si la fonction de coût ne permet pas une discrimination suffisante entre le contour du cerveau et les autres contours. Or la mise en oeuvre d'une fonction qui donne plus d'importance à un contour qu'à un autre n'est pas évidente dans un cadre de fusion d'informations de bas-niveau.

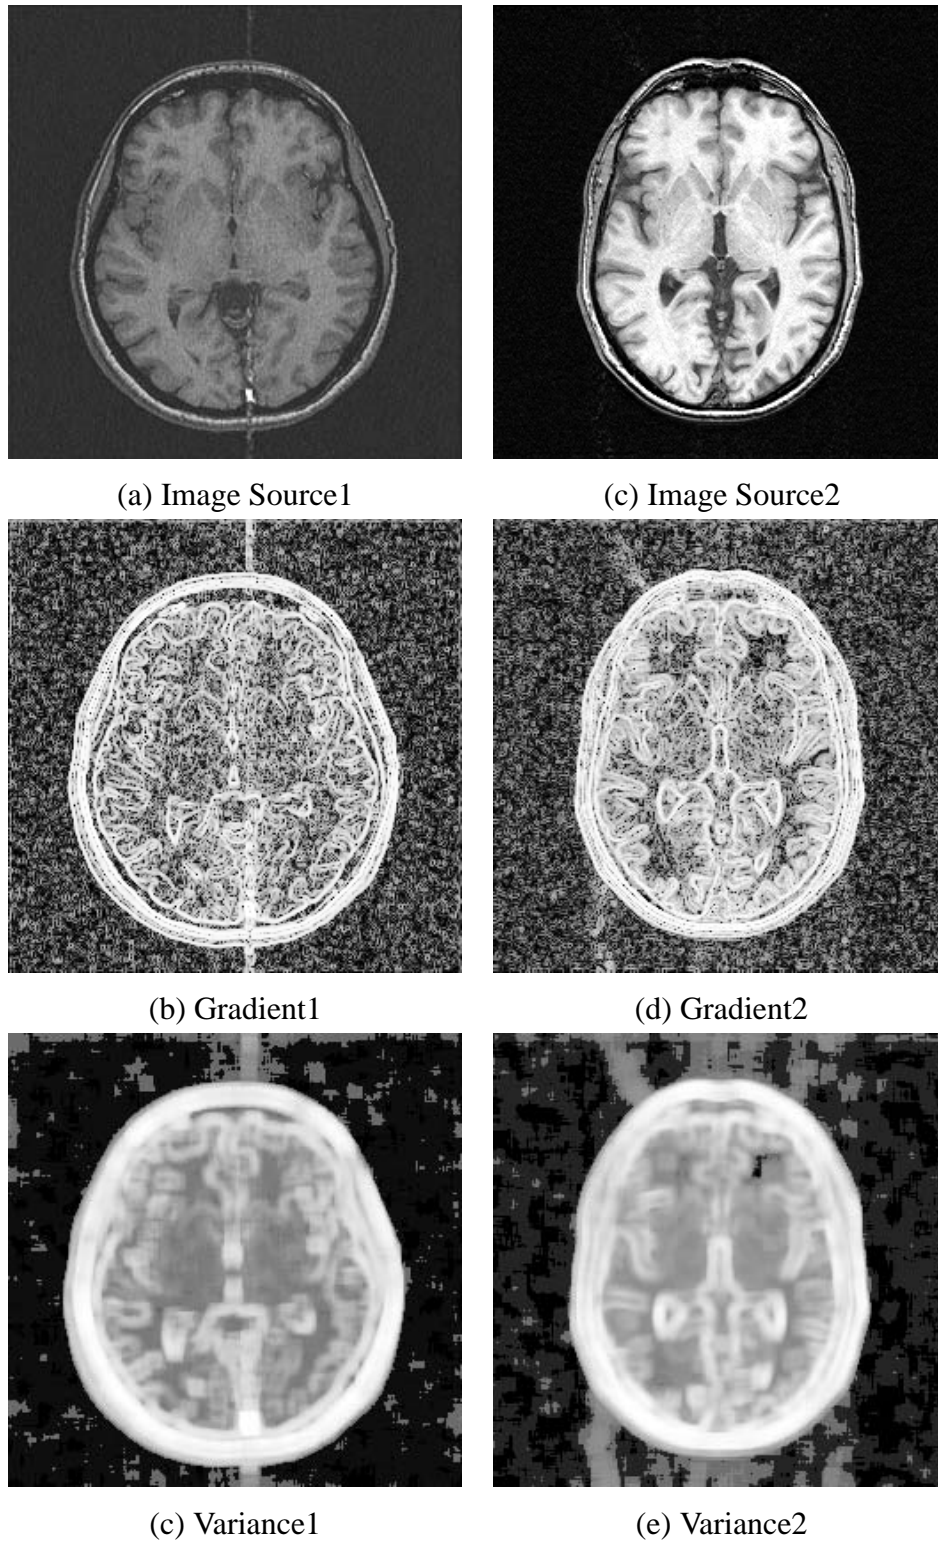


FIG. 4.12: Difficulté de l'extraction des informations de bas niveau pour les images Source1 (issue de la séquence 1 (voir 1.2.5) et Source2 (issue de la séquence 2) différentes.

Plusieurs approches peuvent être envisagées afin de résoudre ce problème. Une première approche assez naturelle consiste à introduire de la connaissance *a priori* sur le contour recherché. Ainsi, dans [Barret 97] un apprentissage interactif de la nature du contour du cerveau est mis en oeuvre. A l'issue de cet apprentissage, la fonction de coût est adaptée afin de favoriser le contour du cerveau.

Notre approche ne se situe pas dans un cadre interactif et nous recherchons plutôt un moyen automatique d'introduction d'informations dans le système pour guider le processus de reconnaissance. C'est pourquoi nous proposons de mettre en oeuvre un autre type d'approche fondé sur l'utilisation d'informations de plus haut-niveau.

Nous verrons comment l'approche que nous proposons exploite un apprentissage effectué très en amont du processus de segmentation. L'utilisation d'un modèle statistique déformable du contour du cerveau constitue en effet un apprentissage important sur sa nature et son apparence. C'est cet apprentissage qui sera exploité indirectement dans notre processus de détection de contours.

4.2.1.2 Choix des sources d'information.

Comme nous l'avons montré ci-dessus, l'exploitation d'informations de bas-niveau, issues de traitements locaux comme pour le gradient, est délicate et peut mener à des confusions.

L'idée que nous mettons en oeuvre ici est de chercher à exploiter plutôt des informations de plus haut-niveau, contenant déjà un résultat d'interprétation et facilitant l'introduction de connaissance dans la fonction de coût.

Il est cependant nécessaire de conserver une attitude prudente face aux résultats d'interprétation qui peuvent contenir des informations erronées. C'est pourquoi nous proposons de coupler deux formes indépendantes d'information issues d'une part de traitements menant à une information de plus haut-niveau et d'autre part de traitements menant à une information de plus bas-niveau. Ainsi, les deux sources d'information que nous couplons sont les suivantes :

- Le résultat de la segmentation, par des agents région, de la matière grise et de la matière blanche, obtenu à l'issue de la première phase d'exécution du système.
- Le résultat de la détection des contours, obtenu par un opérateur plus fin qu'un gradient et décrit dans la partie 3.3.

L'intérêt de coupler ces deux formes d'informations est essentiellement qu'elles sont **complémentaires** et **spatialement cohérentes**.

4.2.1.3 Complémentarité des informations

La complémentarité entre les informations de type région et les informations de type contours est depuis longtemps admise en traitement d'images. De nombreuses approches [Pavlidis 90], [Chun 96] ont déjà été proposées pour améliorer la qualité de la segmentation au travers de méthodes coopératives, essentiellement dans un but de contraindre mutuellement les détecteurs de régions et de contours.

L'intérêt de notre approche réside dans l'utilisation d'une part d'information de bas-niveau telle que le résultat du détecteur de contours et d'autre part d'information de plus haut-niveau telle que le résultat interprété de la segmentation en régions.

L'intérêt de l'utilisation d'informations de haut-niveau est de permettre l'intégration de connaissances directement dans la fonction de coût qui guidera les agents A^* .

En effet, la frontière entre la matière grise et le liquide céphalo-rachidien, qui nous intéresse plus particulièrement, peut être reconnue et localisée grâce à la connaissance de la nature des régions segmentées.

L'intérêt de l'utilisation conjointe d'un détecteur de contours est de fournir une information robuste sur la localisation des contours. Cette information est complémentaire de l'information sur les régions et son utilisation a pour objectif de corriger les défauts de localisation de la segmentation en régions.

La figure 4.13 présente les deux sources d'information que nous avons sélectionnées pour les images Source1 et Source2.

4.2.1.4 Cohérence spatiale des informations

La validation de la segmentation en régions obtenue par des agents spécialisés n'est pas réalisable de manière fiable sur des images réelles. Par contre, il est possible de visualiser simultanément les deux sources d'information que nous souhaitons fusionner en les superposant dans une même image.

L'image de superposition constitue une validation visuelle du résultat, sachant que la qualité principale du détecteur de contours que nous utilisons est une localisation précise.

La figure 4.14 présente le résultat fourni par le détecteur de contours superposé à la segmentation en régions.

Les résultats obtenus à travers ces superpositions montrent une bonne cohérence entre les deux sources d'information. C'est cette cohérence, associée à leur complémentarité qui a guidé

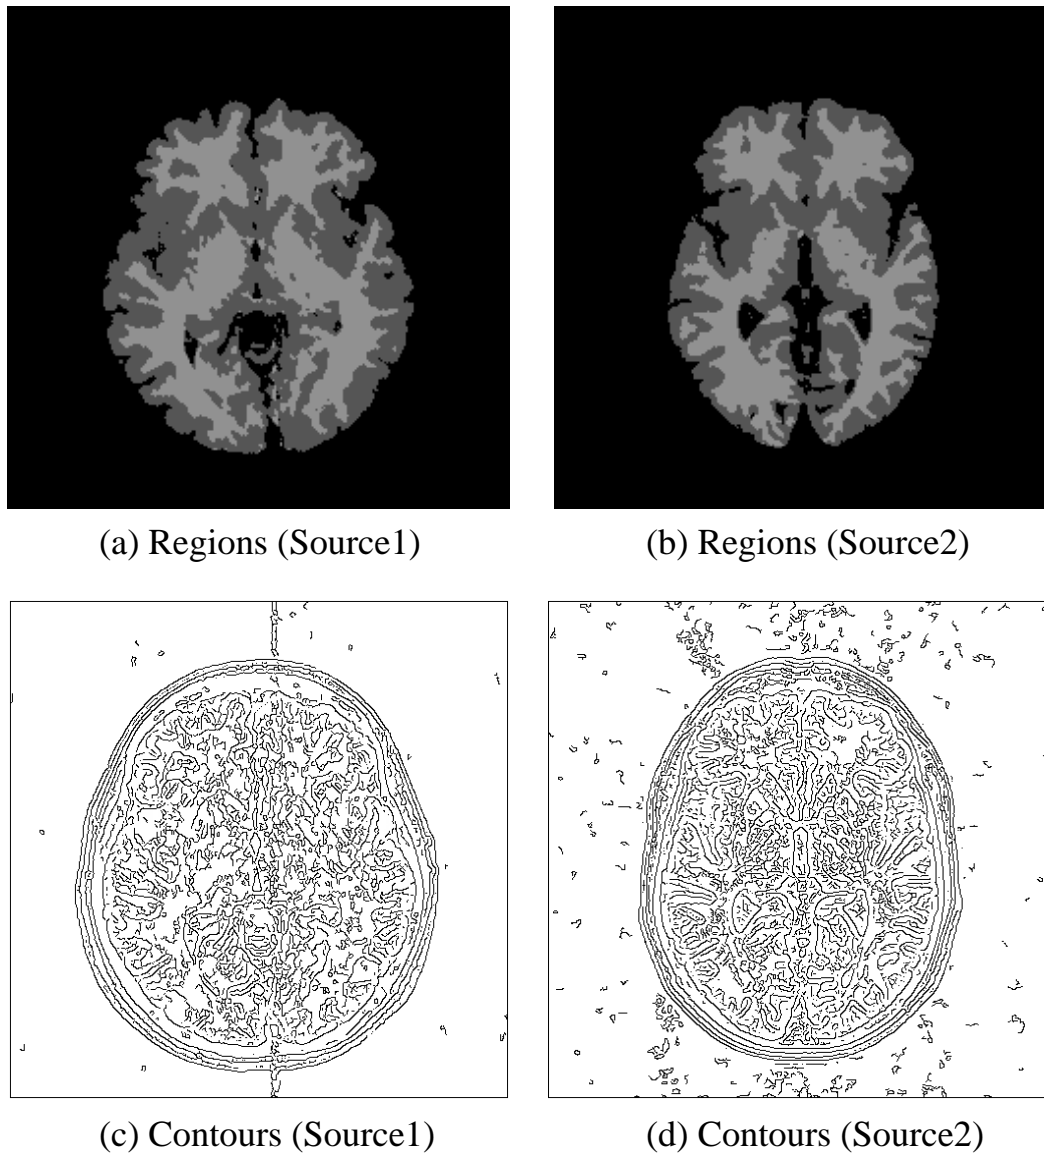


FIG. 4.13: . Exemples des 2 sources d'informations retenues pour générer la fonction de coût des agents A^* . (a), (b) Segmentation en régions par les agents régions spécialisés. (c) et (d) Détection des contours issue du détecteur de contours.

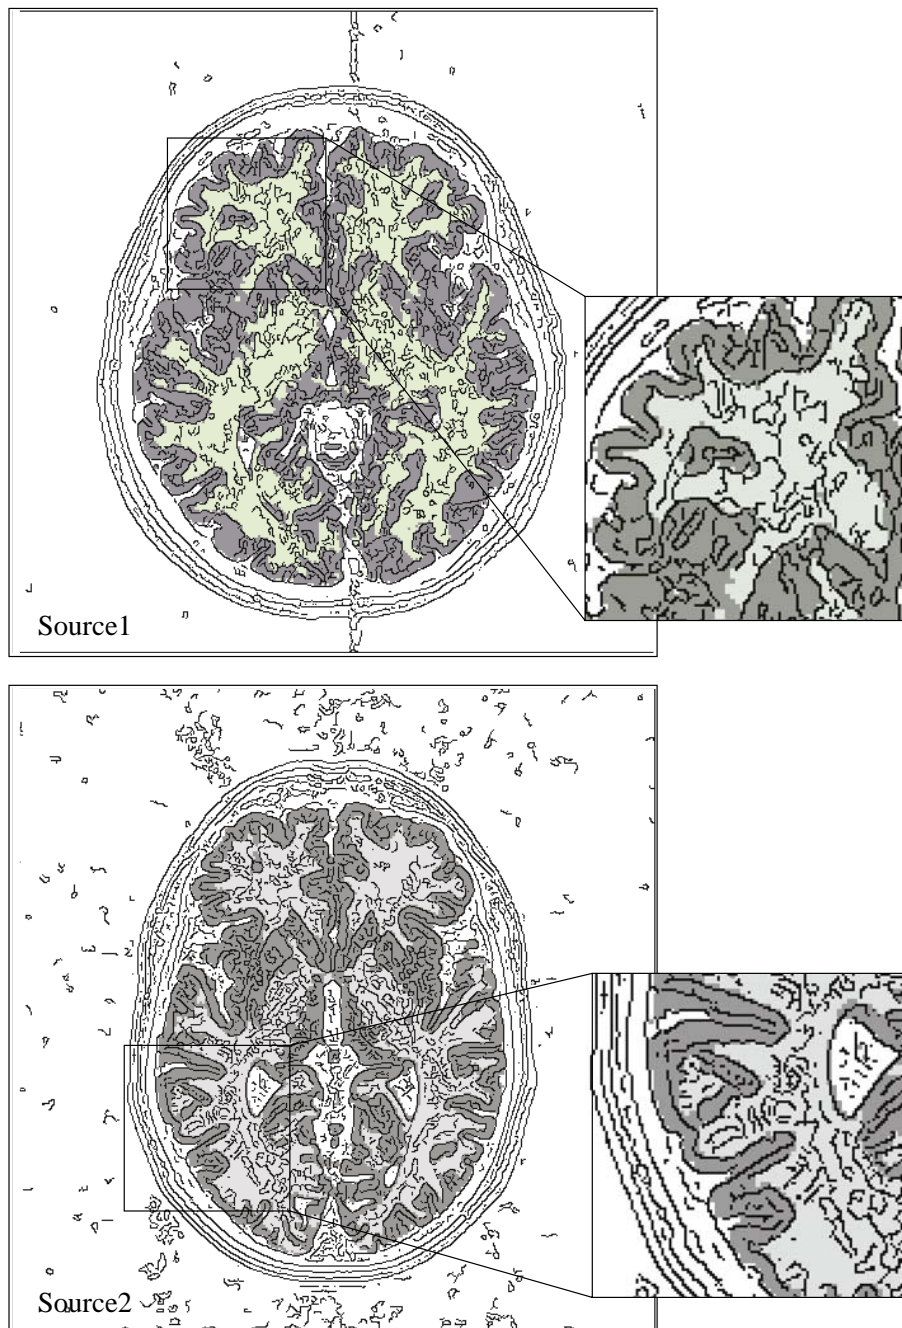


FIG. 4.14: . Images issue de la superposition entre le résultat de la segmentation en régions et le résultat fourni par le détecteur de contours. On observe une bonne cohérence des informations, bien que des inexactitudes soient observables au niveau des frontières.

la recherche d'un principe de fusion dans le but de générer une fonction de coût pour guider des agents A^* .

4.2.1.5 Choix des informations à fusionner.

A l'issue de notre choix de sources d'informations, les données que nous envisageons de fusionner sont de nature binaire :

- Un pixel appartient à la matière grise, à la matière blanche ou au fond pour l'information issue de la segmentation en régions.
- Un pixel appartient à un contour ou au fond pour l'information issue du détecteur de contours.

Ce type d'informations binaires ne se prête pas aisément à des opérations de fusion essentiellement parce qu'il est trop limitatif par rapport aux possibilités de combinaison des informations.

Nous avons donc cherché à exploiter les résultats de la segmentation en région et de la détection des contours dans un cadre moins strict, en leur associant des cartes de distance du chanfrein (3, 4) de masques 3x3.

Pour l'image des régions, nous avons retenu l'information de distance à la frontière entre la matière grise et le fond, frontière proche du contour recherché.

Pour l'image de contours nous avons simplement calculé la carte de distance à tout contour de l'image binaire issue du détecteur.

L'intérêt de remplacer l'information brute par des informations de distances est que cela permet d'introduire une notion d'imprécision dans nos données. De plus cela permet de positionner le problème de fusion que nous nous posons dans un cadre de fusion d'informations floues et ainsi d'utiliser des opérateurs déjà établis dans un tel cadre.

4.2.2 Choix d'un opérateur de fusion

Nous avons montré que les informations sur la distance à la frontière du cerveau et la distance aux contours jouent un rôle important et que l'on peut s'orienter vers une fusion des cartes de distance correspondantes.

Dans ce contexte, nous avons recherché un opérateur de fusion parmi ceux proposés dans [Bloch 96]. Les opérateurs de fusion y sont classifiés selon leur comportement et associés à des notions qualitatives telles que la sévérité, l'indulgence ou la prudence.

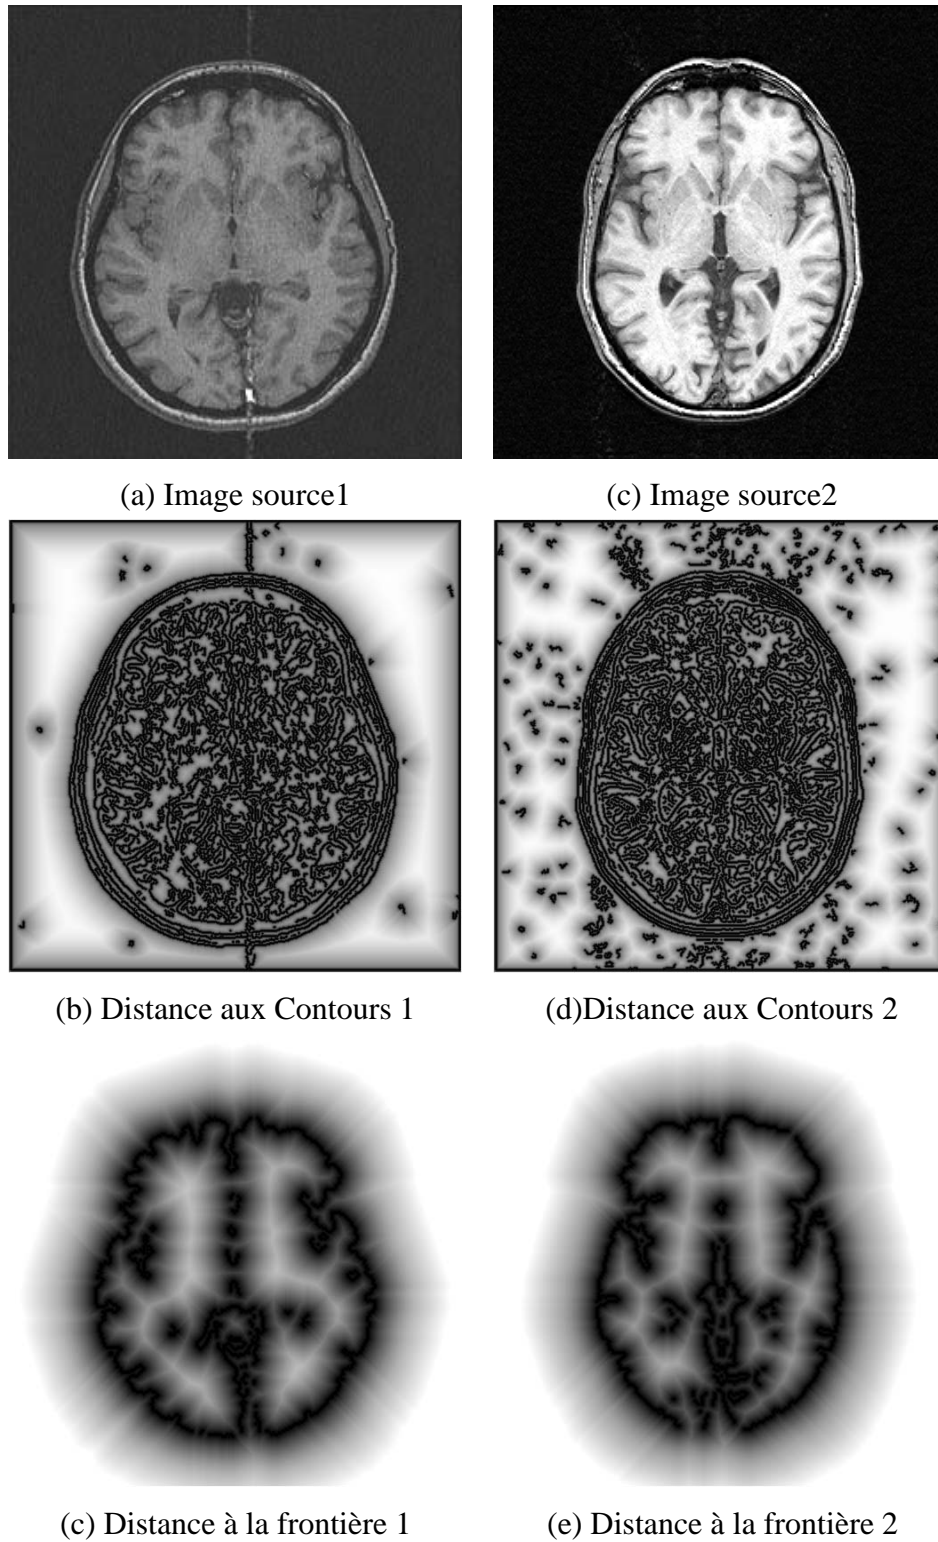


FIG. 4.15: (a),(c) Images sources. (b), (d) Cartes de distance associées aux contours.(c), (e) Cartes de distance associées à la frontière entre matière grise et fond.

On note x et y les deux variables à combiner, généralement comprises dans l'intervalle $I = [0, 1]$ et F la fonction agissant sur x et y .

On dit d'un opérateur qu'il est conjonctif si $F(x, y) \leq \min(x, y)$ ce qui correspond à un comportement sévère. F est disjonctif si $F(x, y) \geq \max(x, y)$, ce qui correspond à un comportement indulgent. Enfin, F est un opérateur de compromis si $x \leq F(x, y) \leq y$ pour $x \leq y$ et si $y \leq F(x, y) \leq x$ pour $y \leq x$, ce qui correspond à un comportement prudent.

A partir de cette description des comportements, il est possible de distinguer trois grandes classes d'opérateurs de fusion :

- Les opérateurs autonomes à comportement constant (CICB : Context Independent Constant Behaviour) ont toujours le même comportement quelles que soient les valeurs de x et y .
- Les opérateurs autonomes à comportement variable (CIVB : Context Independent Variable Behaviour) ont un comportement qui varie en fonction des valeurs de x et y .
- Les opérateurs dépendant du contexte (CD : Context Dependand) dont le comportement varie à la fois en fonction des valeurs de x et y et d'informations extérieures qualifiées de contexte.

Dans notre cas, nous avons recherché un opérateur induisant un comportement de compromis qui traduise la cohérence entre les sources d'information. L'étude des travaux de Huet [Huet 99] sur la fusion d'images interprétées a inspiré le choix d'un opérateur de type barycentre, qui nous permet de pondérer les sources d'information en fonction de la confiance que nous leur accordons.

L'opérateur que nous avons retenu est présenté dans l'équation 4.3, où $f_i(p)$ représente le coût associé au pixel p , le couple (β, γ) représente les coefficients de pondération du barycentre, $I'_R(p)$ l'information de distance à la frontière matière grise/fond et $I'_C(p)$ l'information de distance aux contours.

Une phase de normalisation est nécessaire afin de construire la fonction de coût. Ainsi, en notant I_{RMAX} et I_{CMAX} les valeurs maximales respectivement observée pour l'information région et pour l'information contour, et en notant $I_R(p)$ et $I_C(p)$ les informations de distances aux régions et aux contours (4.2), on obtient (4.3) :

$$I'_R(p) = \frac{I_R(p)}{I_{RMAX}} \quad I'_C(p) = \frac{I_C(p)}{I_{CMAX}} \quad (4.2)$$

$$f_i(p) = \frac{\beta I'_C(p) + \gamma I'_R(p)}{\beta + \gamma} \quad (4.3)$$

4.2.3 Fonctions de coût

D'après la construction de notre opérateur de fusion, la fonction f est minimale aux pixels correspondant à une bonne cohérence entre les sources d'information. Dans le contexte de la programmation dynamique, il est donc possible d'utiliser directement le résultat de la fusion des informations comme fonction de coût pour guider les agents A^* .

Le choix des coefficients de pondération a été effectué expérimentalement. Etant donné que nous combinons deux sources d'information et dans le but de restreindre l'espace de recherche des coefficients, nous avons limité à deux le nombre de couples (β, γ) étudiés.

Le but est d'étudier l'effet du déséquilibre de ces coefficients sur les résultats de la détection du contour du cerveau. Il est possible de pondérer plus fortement soit l'information issue des régions, soit l'information issue des contours.

La première possibilité est de donner une importance prépondérante à l'information de type région. Cette information a en effet été obtenue à l'issue de la segmentation en régions et fournit un moyen d'affiner le contour du cerveau en l'attirant vers la frontière, tout en conservant sa topologie et en supprimant les contraintes de déformations globales issues du modèle.

Dans ce contexte, le choix des coefficients est fixé à $(\beta, \gamma) = (1, 3)$, et deux exemples des fonctions de coût et des résultats du contour obtenus sont présentés dans les figures 4.16(a) et 4.17(a) pour deux images issues de séquences d'acquisition différentes.

La seconde possibilité pour le choix des coefficients est de donner plus d'importance aux contours. Cela est intéressant dans la mesure où l'information sur les contours fournit une bonne localisation de ces contours. Ainsi, pour s'affranchir des erreurs potentiellement présentes dans le résultat de la segmentation en régions ou bien effectuer une transmission d'information, il est souhaitable d'utiliser cette fonction.


Dans ce contexte, le choix des coefficients est fixé à $(\beta, \gamma) = (3, 1)$. Les figures 4.16(c) et 4.17(c) présentent les fonctions de coût obtenues pour ce choix de coefficients, ainsi que les résultats correspondants.

On remarquera que les détails des contours, qui étaient absents de la première fonction de coût ($(\beta, \gamma) = (1, 3)$), sont nettement visibles pour la deuxième fonction ($(\beta, \gamma) = (3, 1)$). Cela montre bien que l'effet d'attraction sera plus important vers les zones contenant des contours issus du détecteur de contours. La notion de barycentre adoptée dans le choix de l'opérateur de fusion est bien illustrée par la différence d'allure des fonctions de coût ainsi construites.

Comme pour toute fonction dépendant de paramètres, le choix définitif des coefficients à affecter à l'opérateur de fusion que nous avons retenu est délicat. Le seul moyen objectif est




(a) Fonction de coût (1, 3)



(b) Résultat 1



(c) Fonction de coût (3, 1)




(d) Résultat 2

FIG. 4.16: (a) et (c) Fonctions de coût. (b),(d) Résultats obtenus pour une image de la séquence d'acquisition 1..




(a) Fonction de coût (1, 3)



(b) Résultat 1



(c) Fonction de coût (3, 1)



(d) Résultat 2

FIG. 4.17: (a) et (c) Fonctions de coût. (b)(d) Résultats obtenus pour une image de la séquence d'acquisition 3.

d'évaluer la qualité des contours détectés par des agents A^* guidés soit par l'une ou l'autre des pondérations que nous avons présentées dans cette section. Le choix définitif sera effectué dans le chapitre 5.

4.2.4 Position et nombre des agents A^*

La position des agents A^* est choisie sur le contour issu du modèle déformable, de façon à ce que la longueur de contour le long du modèle soit la même pour chaque agent.

Outre la position, il est nécessaire de choisir le nombre d'agents A^* qui seront utilisés pour la détection du contour du cerveau.

Ce choix est un compromis entre un petit nombre d'agents pour la simplicité du problème et un nombre important d'agents pour la rapidité de détection d'une section du contour à reconstruire.

Il faut prendre en compte dans la détermination du choix du nombre d'agents A^* un certain nombre de caractéristiques propres à ce type de contours. En effet, la détection des chemins optimaux du graphe mène couramment à la recherche de contours de plus faible longueur. Dans nos expérimentations, nous avons rencontré les situations résumées dans la figure 4.18. Ces situations montrent que 2 agents ne suffisent pas à reconstruire le contour que nous recherchons, car ils ont tendance à "couper" à travers le cerveau. Le même problème a été observé pour 3 agents et disparaît à partir de 4 agents.

Nous avons finalement choisi de positionner 5 agents car cela permet de s'affranchir du problème de traversée du cerveau et également de réduire, pour chaque agent, la taille de la zone d'exploration, et par conséquent d'accélérer la détection.

Un nombre d'agents supérieur à 5 a une influence mineure sur les résultats obtenus. La connectivité des 5 morceaux de contours est garantie par le choix des extrémités des agents, ainsi, la fin d'un contour correspond au début du suivant.

4.2.5 Heuristiques

Le principe de représentation des régions et des contours adopté dans le contexte de la détection des contours, qui consiste à insérer un pixel contour entre deux pixels région, conduit à la manipulation d'images de taille double de l'image source. Ainsi, la taille des images obtenues en sortie du détecteur de contours est le plus couramment de 512x512 pixels.

Lors de la fusion des informations il est nécessaire d'avoir une taille identique pour les deux sources. Plutôt que de diviser l'image issue du détecteur par deux, nous préférons conserver une

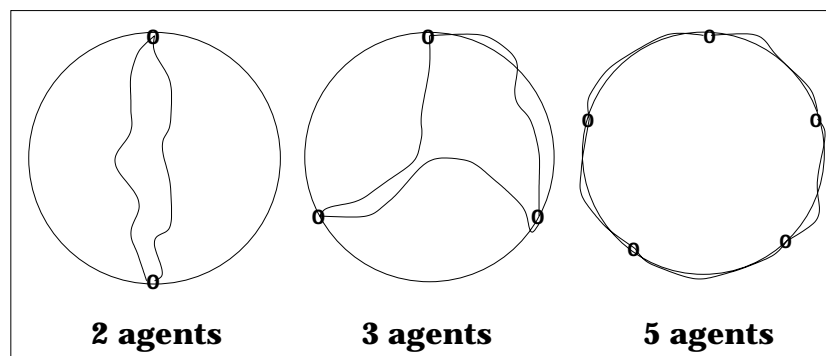


FIG. 4.18: Allures des contours détectés en fonction du nombre d'agents A^* initialisés. Le cercle symbolise le résultat issu du modèle déformable.

taille double. Cela est justifié par le fait que l'on a des informations plus précises sur la localisation des contours à une résolution double. Les images manipulées sont donc de taille importante.

Lorsque l'on détecte le contour du cerveau avec les agents A^* , on choisit en général d'initialiser 5 agents. Les fenêtres d'exploration de chemins correspondant à chaque agent ont alors en moyenne des tailles de l'ordre de 200×200 , soit 40000 pixels à explorer pour l'algorithme A^* .

Sans heuristique, le temps de calcul pour la détection du modèle est donc beaucoup trop long et il est nécessaire d'envisager la mise en oeuvre d'heuristiques.

Dans le cadre de notre application, les modifications que l'on souhaite apporter au modèle déformable sont en général relativement faibles et dans tous les cas le contour généré par les agents A^* est peu éloigné de la frontière de la matière grise.

Nous proposons de mettre en oeuvre une heuristique permettant de réduire fortement le nombre de pixels à explorer. Cette heuristique consiste à n'explorer que les pixels situés à une distance inférieure à 40 pixels de la frontière entre matière grise et fond (fig. 4.19). La longueur du contour étant en moyenne égale à 500 pixels, chaque section a une longueur de 100 pixels environ et le nombre de pixels explorés devient environ 4000. Des exemples de taux de réduction du nombre de pixels à explorer sont présentés dans le tableau (fig. 4.20).

En pratique, l'heuristique est directement introduite dans le calcul de la fonction de fusion en affectant aux pixels situés trop loin de la frontière matière grise/liquide céphalo-rachidien une valeur interdite.

Lors de l'exécution de l'algorithme A^* , ces pixels ne pourront pas être sélectionnés comme successeurs potentiels d'un contour en cours de construction.

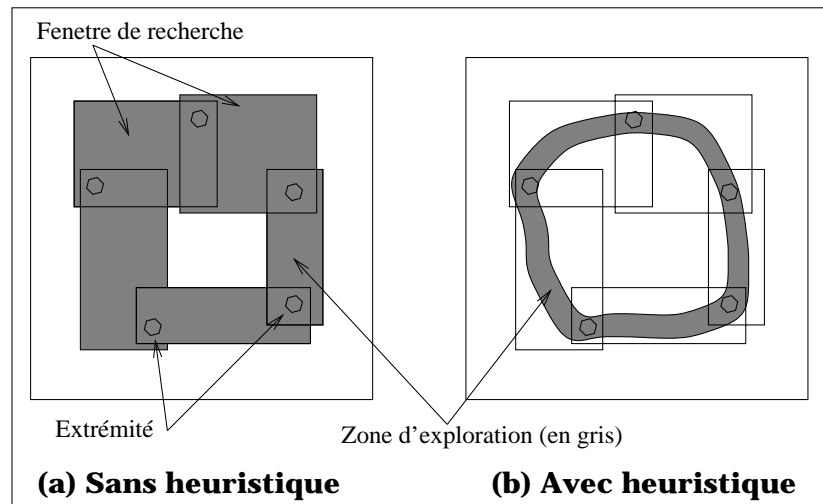


FIG. 4.19: La zone d'exploration est représentée en grisé. L'heuristique consiste à n'explorer que les pixels situés près du contour précédemment trouvé pour le cerveau.

	Fenêtre de recherche	Nombre de pixels	Facteur de réduction
Exemple 1	246x147	≈ 36000	≈ 9
Exemple 2	182x250	≈ 45000	≈ 11
Exemple 3	236x196	≈ 46000	≈ 11
Exemple 4	94x236	≈ 22000	≈ 5

FIG. 4.20: Facteur de réduction du nombre de pixels à explorer.

Bilan sur la coopération par fusion d'informations

La détection du contour du cerveau est un problème très étudié en IRM cérébrale. Les approches qui ont été utilisées pour résoudre ce problème sont essentiellement fondées sur les contours déformables, comme les contours actifs ou les modèles déformables.

Le principal écueil rencontré dans l'ensemble de ces approches est que les contours sont soumis à des ensembles de contraintes de déformations globales.

L'existence de ces contraintes globales peut être souhaitable dans une certaine limite. Par exemple, le modèle déformable que nous utilisons est soumis à des contraintes qui assurent la robustesse des résultats, ce qui est important.

Les contours actifs sont également soumis à des contraintes de rigidité qui permettent d'obtenir des contours plus fiables.

Cependant, le contour du cerveau présente de nombreuses convolutions qu'il est important de repérer pour de nombreuses applications. Dans un tel contexte, il devient nécessaire de pouvoir s'affranchir des contraintes de rigidité et de permettre aux contours de mieux suivre les convolutions du cerveau.

Nous verrons dans le chapitre 5 que la mise en oeuvre du processus de fusion permet d'affiner la qualité du contour détecté pour le cerveau.

On peut se demander pourquoi nous n'avons pas choisi d'utiliser une approche de type contours actifs pour effectuer la détection du contour du cerveau. La première raison est que le principe d'optimisation utilisé pour les contours actifs est proche du principe d'optimisation utilisé par le modèle déformable, et que par conséquent les contours actifs n'apparaissent pas comme une approche suffisamment complémentaire. Une seconde raison est que les contours actifs sont soumis à des contraintes de rigidité internes. Ils ne peuvent donc pas avoir autant de capacité à suivre des convolutions que nos contours A^* . En effet, nos agents spécialisés n'intègrent aucune contrainte sur la rigidité des contours à détecter. De plus, les agents procèdent par optimisations sur des sections de contours et non globalement.

Il serait toutefois intéressant d'exploiter la fonction de fusion que nous proposons pour guider la déformation d'un contour actif. En effet, à notre connaissance, les fonctions d'énergie utilisées pour les contours actifs n'intègrent pas de connaissance de plus haut niveau telle que le résultat d'une segmentation en régions.

Le principe de coopération que nous avons proposé dans cette partie admet cependant des limites et ne permet pas de résoudre complètement le problème de la détection des sillons corticaux.

En effet, un algorithme de minimisation (ou d'optimisation d'énergie) aura toujours ten-

dance à favoriser des chemins plus courts et par conséquent moins convolués. C'est pourquoi une des perspectives de ce travail est la mise en oeuvre, selon un principe de coopération par fusion similaire, d'un ensemble d'agents contours spécialisés pour la détection des sillons.

4.3 Coopération par rétroaction

La coopération par rétroaction est un principe de coopération qui consiste à exploiter le résultat d'une approche pour recommencer l'exécution de cette même approche dans un but d'amélioration de la solution qui a été proposée à un instant donné.

Dans ce travail, la coopération par rétroaction est intimement liée à la coopération par fusion dans le sens où la fusion permet d'envisager la rétroaction.

L'exigence de conservation de la topologie que nous avons eue pour la coopération par fusion ne présente pas seulement un intérêt pour la détection du contour du cerveau, mais aussi pour une rétroaction globale sur notre processus complet de segmentation.

En effet, à l'issue de la phase de coopération par fusion, le contexte général est exactement le même qu'à l'issue de la recherche du contour du cerveau par le modèle déformable.

Il est donc possible d'envisager le remplacement du modèle par le contour détecté.

La possibilité de rétroagir sur notre processus complet de segmentation nous est d'abord apparue comme un moyen d'améliorer nos résultats sur une coupe donnée. En effet, le modèle déformable, soumis à des contraintes globales, est utilisé pour limiter et contraindre la croissance des agents région.

Il est donc possible que des agents soient trop contraints ou bien incorrectement contraints et la rétroaction apparaît alors comme un moyen de correction. Nous verrons dans cette partie les résultats obtenus dans ce contexte et nous visualiserons la stabilité du contour détecté après quelques étapes de rétroaction.

Une autre possibilité d'exploitation de la rétroaction que nous avons étudiée est la transmission du contour obtenu de coupe en coupe. Ce principe de rétroaction est essentiellement intéressant pour pallier la non-existence d'un modèle déformable 3D, et permettre quand même une segmentation 2.5D.

La mise en oeuvre du principe de rétroaction entre coupes fait également intervenir la rétroaction sur même coupe car le contour transmis est de fait inexact et il est nécessaire de le corriger avant de le transmettre à nouveau à une autre coupe.

Nous présentons dans cette partie les deux principes de rétroaction que nous avons mis en oeuvre :

1. La rétroaction sur même coupe.
2. La rétroaction sur coupe adjacente.

4.3.1 Rétroaction sur la même coupe

Dans le but d'affiner le résultat, nous avons cherché à détecter un contour contenant plus d'informations que ce qu'un modèle peut fournir. Dans le contexte de la modélisation du cerveau, il n'est en effet pas possible, pour des raisons de variabilités topologiques, de construire un modèle décrivant à la fois l'enveloppe du cerveau et les sillons.

Nous avons donc choisi de construire un modèle déformable de l'enveloppe du cerveau, structure relativement stable d'un individu à l'autre, ce qui permet de tirer parti de la grande robustesse du modèle pour initialiser nos agents de segmentation en régions.

En contrepartie, il nous a semblé que l'information constituée par le résultat de la segmentation en régions pouvait à son tour constituer un apport dans la détection du contour, dans une sorte de "feed-back" de l'information.

4.3.1.1 Objectifs

L'objectif de la rétroaction sur la même coupe est d'affiner le contour détecté par le modèle déformable. Deux choix sont possibles pour la pondération de la fonction de fusion afin de guider cet affinement :

1. Favoriser l'information région issue de la segmentation en régions.
2. Favoriser l'information contours, issue du détecteur de contours.

Dans un premier temps, nous avons effectué des expérimentations en donnant plus de poids au critère région. L'idée sous-jacente était de suivre au mieux la frontière entre région matière grise et fond, tout en la corrigeant localement par l'information contour. Visuellement, les résultats obtenus étaient satisfaisants.

Cependant, les régions sont le résultat d'une croissance de régions contrainte par un contour (issu du modèle déformable ou d'une détection par les agents A^*). Par conséquent, cette information peut être erronée et en particulier, les régions peuvent ne pas atteindre le bords réel du cerveau du fait de cette contrainte. En itérant sur ce processus de rétroaction, des effets d'érosion progressive ont pu être observés.

Favoriser l'information région pour la fonction de fusion revient donc à favoriser une information potentiellement peu fiable ce qui n'est pas souhaitable.

C'est pourquoi nous préconisons de donner plus de poids à une information indépendante, issue de la détection des contours, et qui ne constitue pas un vecteur d'erreurs. Nous verrons dans le chapitre 5 que ces considérations sont confirmées par une qualité supérieure des contours issus d'une fusion donnant plus de poids à l'information contours.

4.3.1.2 Nombre de rétroactions

Au cours de nos expérimentations, nous avons observé une stabilisation rapide du contour détecté. Les modifications les plus importantes interviennent au cours de la première rétroaction puis des modifications moindres peuvent être observées ensuite.

La figure 4.21 illustre le comportement des contours A^* lors de trois répétitions de la rétroaction. Après trois étapes de rétroaction, le contour est stabilisé et il devient inutile de continuer à itérer sur le processus complet.

Finalement, nous estimons qu'au terme de deux ou trois rétroactions le contour est stable et qu'il ne pourra plus être amélioré par l'approche que nous employons.

4.3.2 Rétroaction sur coupe adjacente

L'aspect 2D de notre approche est essentiellement dû au fait que la construction d'un modèle déformable en 3D soulève encore de nombreuses difficultés et que par conséquent nous ne disposons que d'un modèle 2D.

Cependant, nous sommes pleinement conscients de la nécessité de réaliser la segmentation de volumes plutôt que de coupes. C'est pourquoi nous avons étendu notre principe de rétroaction sur même coupe à un principe de rétroaction sur une coupe adjacente.

Cela permet de réaliser une segmentation qualifiée de 2.5D puisque les résultats sont obtenus à partir de processus 2D et non 3D.

4.3.2.1 Objectifs

Un tel mode de rétroaction permet de transmettre le résultat du contour du cerveau à une coupe proche pour débiter un processus complet de segmentation et construire un contour sur une nouvelle coupe.

L'objectif est de ne plus avoir besoin du modèle pour initialiser la segmentation. Ce principe de transmission est possible car l'épaisseur des coupes est faible (1mm) et que la surface du cerveau est relativement "continue". Par conséquent, les déformations du contour entre deux coupes successives ne sont pas trop importantes et peuvent être prises en compte dans un processus de rétroaction.

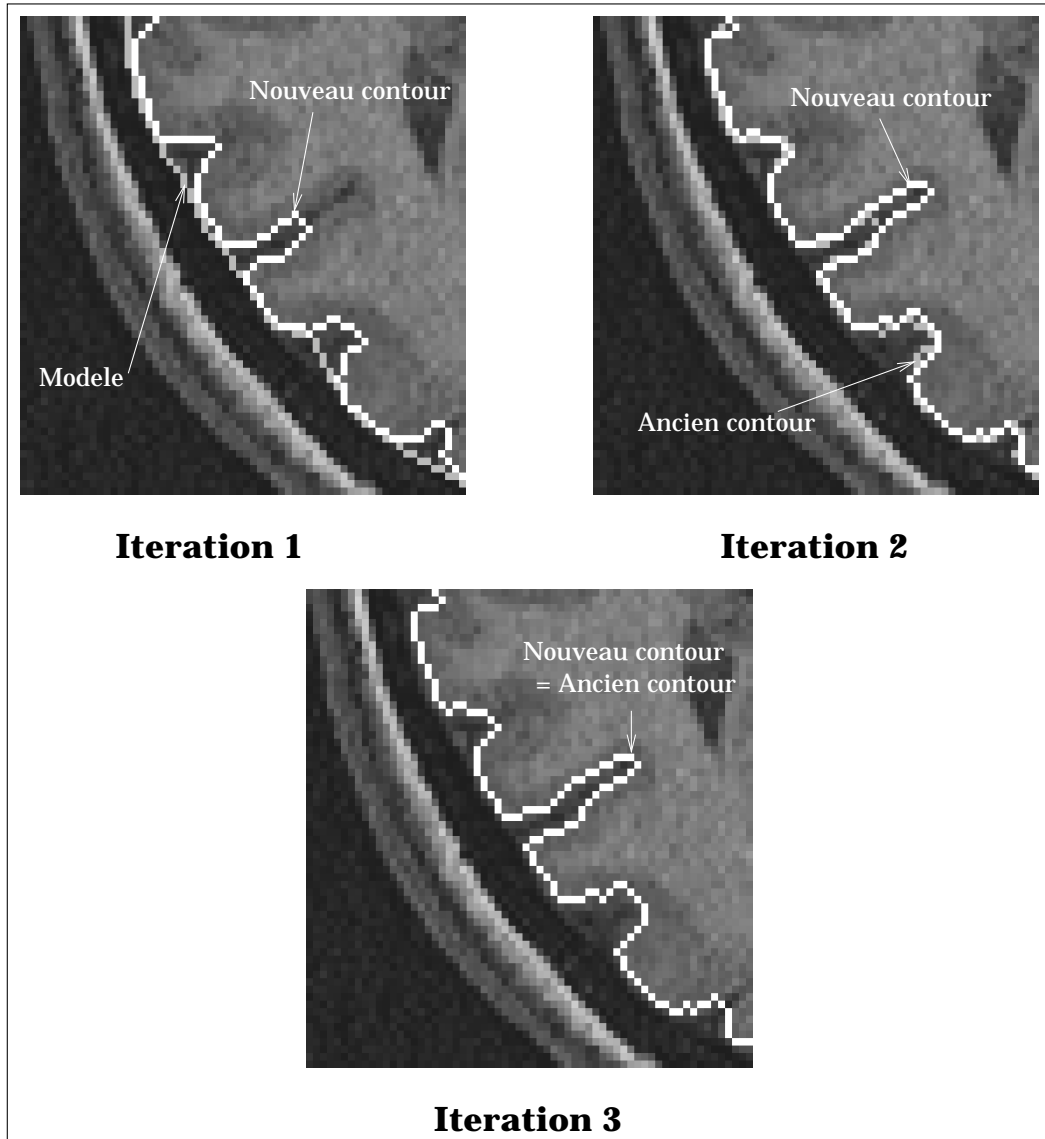


FIG. 4.21: Détection d'un sillon "ouvert" avec 3 phases de rétroaction. Le contour se stabilise après trois exécutions.

4.3.2.2 Processus de transmission des informations

Le processus de rétroaction que nous avons mis en oeuvre comporte deux phases afin de segmenter des coupes successivement dans le volume d'acquisition. Les deux étapes sont les suivantes :

- La première phase consiste à utiliser le contour issu de la coupe précédente pour initialiser le processus de segmentation.

Cela permet de réaliser une segmentation en régions pour corriger les erreurs de détection du contour du cerveau dues au changement de coupe.

- La seconde phase consiste à effectuer une nouvelle itération sur le processus complet de segmentation dans le but d'affiner le résultat pour les régions et pour le contour du cerveau.

A l'issue de cette étape on obtient le contour qui sera transmis à la coupe suivante.

Dans la figure 5.33, nous présentons les contours détectés à l'issue du double processus de rétroaction exploitant deux fonctions de fusion.

Dans un premier temps, l'utilisation de la fonction de coût pondérée par $(\beta, \gamma) = (3, 1)$ permet de récupérer les pixels situés au bord du cerveau et qui n'ont pas été segmentés en tant que matière grise à cause des contraintes appliquées à la croissance de région.

Dans un second temps, on inverse les pondérations pour donner plus de poids à l'information région.

Les contours obtenus avec les deux fonctions de fusion sont globalement semblables, avec parfois des écarts locaux en particulier au départ de sillons.

Sans carte de référence, il est difficile de préconiser un choix de paramètres. Pour les expérimentations sur des images réelles, le contrôle reste manuel et fondé sur une expertise visuelle des résultats.

Bilan sur la coopération par rétroaction

La mise en oeuvre du processus de coopération par rétroaction nous a permis de tirer parti de la phase de coopération par fusion d'informations pour réaliser deux objectifs complémentaires :

- Rétroagir sur une même coupe dans le but d'affiner la solution proposée.
- Transmettre le résultat du contour du cerveau à une coupe adjacente du volume d'acquisition pour permettre une segmentation 2.5D.

L'intérêt de ce processus de rétroaction est qu'il permet d'une part de corriger les résultats et d'autre part de transmettre les informations.

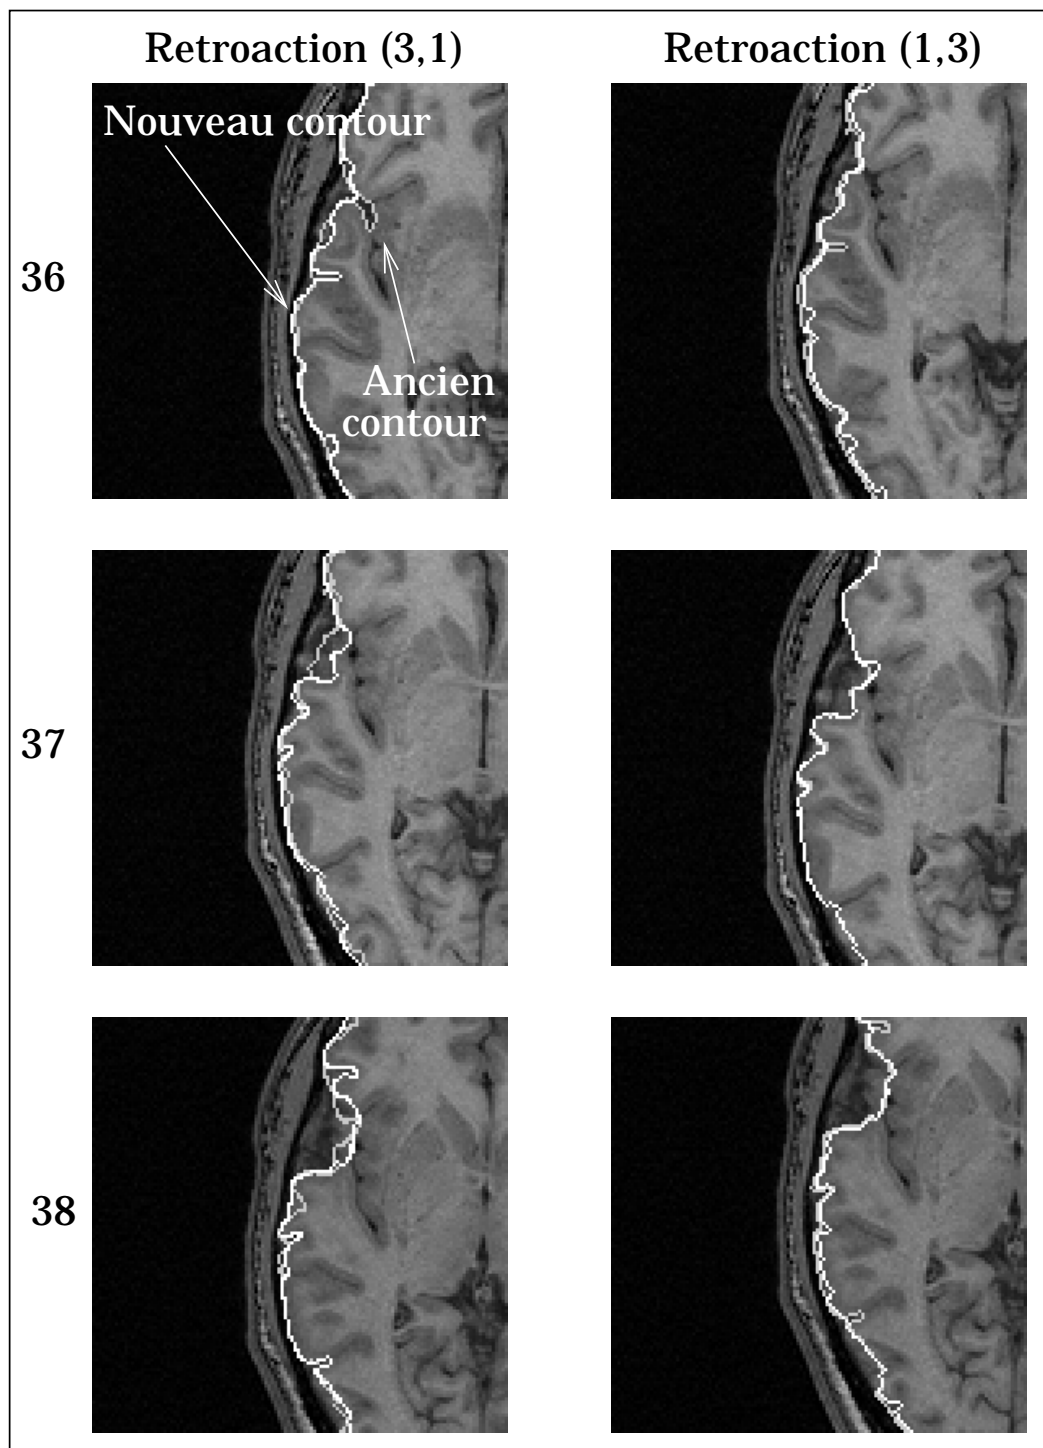


FIG. 4.22: Rétroaction pour la transmission de coupe en coupe. La fonction de coût utilisée a successivement les paramètres $(\beta, \gamma) = (3, 1)$ et $(\beta, \gamma) = (1, 3)$

Cependant, ce processus de rétroaction ne permet pas d'exploiter complètement la tri-dimensionnalité des données étudiées.

Ainsi, nous ne tirons pas parti des informations constituées par la segmentation en régions lors de la transmission de coupe en coupe, informations qui pourraient être utilisées comme connaissance *a priori* et permettre un enrichissement du processus de croissance de régions.

Conclusion

Dans ce chapitre nous avons mis en oeuvre trois principes de coopération dans le but de réaliser la segmentation de la matière grise et de la matière blanche, puis d'affiner le contour du cerveau et enfin de le transmettre à travers le volume étudié dans un cadre 2.5D.

Ces principes de coopération ont donc permis de réaliser des objectifs complémentaires en termes de type d'informations générées (régions et contours).

L'intérêt essentiel de la mise en oeuvre de principes coopératifs est de permettre l'intégration au sein d'un même système d'approches hétérogènes et de tirer parti de ces hétérogénéités afin de construire un résultat.

Il n'était en effet pas évident *a priori* de définir des moyens de combiner les informations produites par les différentes approches mises en oeuvre.

Ainsi, la coopération par initialisation a permis d'exploiter le résultat fourni par une approche fondée sur un modèle déformable pour générer des agents de segmentation région spécialisés.

La coopération par fusion a permis de combiner une information de haut-niveau (segmentation en régions) et une carte de contours bas-niveau pour affiner le contour du cerveau.

Enfin la rétroaction est apparue comme un moyen de corriger les résultats ou de les transmettre.

Cependant, tous ces principes admettent des limites. Par exemple, le principe de coopération par initialisation que nous avons adopté ne permet pas de segmenter d'abord la matière blanche, alors que celle-ci est plus homogène.

La coopération par fusion nécessite de fixer des pondérations sur les informations utilisées et l'utilisation de la programmation dynamique est contraignante en termes de temps d'exécution. Enfin, la rétroaction est intéressante pour pallier l'absence d'un modèle déformable 3D, mais il serait évidemment très souhaitable de pouvoir travailler directement sur les volumes.

Chapitre 5

Validation et résultats

Introduction

Comme dans de nombreux problèmes de segmentation d'images, la validation des résultats obtenus est un problème délicat et plusieurs approches peuvent être envisagées dans le but de fournir une évaluation quantitative de la qualité des résultats.

Nous distinguerons principalement les approches exploitant le résultat de segmentations réalisées manuellement par des experts sur des images réelles et les approches exploitant des images de synthèse pour lesquelles la référence est parfaitement connue.

Dans le contexte de l'IRM cérébrale, le recours à des experts pour segmenter manuellement des images réelles soulève de nombreuses difficultés. En effet, la notion de localisation d'un contour est imprécise et parfois subjective, dépendant notamment de l'expérience de l'expert. Par conséquent, il est très probable que les cartes de références ainsi produites soient en désaccord en de nombreuses zones et que la fiabilité et la reproductibilité des résultats soient difficiles à évaluer.

De plus, la complexité des contours à détecter contribue à rendre une telle tâche extrêmement fastidieuse et coûteuse en temps.

Pour l'ensemble de ces raisons, le recours à des images réelles semble difficile à mettre en oeuvre dans un but de validation, et il semble préférable d'avoir recours à des images de synthèses, idéalement les plus réalistes possibles.

Dans ce travail, nous avons utilisé les images disponibles sur le site Internet du Montréal Neurological Institute [Collins 98]. Ces images ont été construites à partir d'images réelles et sont donc réalistes en termes de géométrie des contours. Les intensités des tissus ont été simulées à l'aide de modèles physiques du processus de résonance magnétique.

Dans ce qui suit nous présentons le principe de construction de plusieurs images de synthèse puis nous validons notre approche sur ces images et nous discutons les résultats obtenus.

Enfin, nous présentons des résultats issus de la segmentation d'images réelles afin de montrer l'allure des résultats obtenus, sans pour autant pouvoir en quantifier la qualité.

5.1 Construction des images de synthèse

La construction des images de synthèse, disponibles sur le site Web (fig. 5.1)

(<http://www.bic.mni.mcgill.ca/brainweb/>)

et décrite en détail dans [Collins 98], a été effectuée à partir de 27 acquisitions réalisées sur un même individu et caractérisées par un rapport signal/bruit élevé. C'est la moyenne de toutes les acquisitions qui constitue le volume initial utilisé pour la construction d'un "fantôme" du cerveau.

BrainWeb: Simulated MRI Volumes for Normal Brain

Select the desired simulated volume using the switches below. These simulations are based on an [anatomical model of normal brain](#), which can serve as the ground truth for any analysis procedure.

Currently, the simulation parameter settings are fixed to three modalities, 5 slice thicknesses, 6 levels of noise, and 3 levels of intensity non-uniformity. Future versions of the SBD will allow the user to specify arbitrary simulation parameters.

Modality: (you can choose one of the following pulse sequences)

T1 ▾ T2 ▾ PD ▾

Slice thickness: (in-plane pixel size is always 1x1mm)

1mm ▾ 3mm ▾ 5mm ▾ 7mm ▾ 9mm ▾

Noise:

0% ▾ 1% ▾ 3% ▾ 5% ▾ 7% ▾ 9% ▾

Intensity non-uniformity ("RF"):

0% ▾ 20% ▾ 40% ▾

FIG. 5.1: Site Web pour la simulation d'images de synthèse du cerveau humain .

Nous résumons ci-dessous les principales étapes qui ont été mises en oeuvre afin de transformer le volume réel initial en un fantôme permettant de générer des simulations :

1. Correction de la non-uniformité :

Avant tout traitement du volume initial, un algorithme de correction de la non-uniformité des niveaux de gris a été appliqué afin de réduire au maximum les risques d'erreurs de classification.

2. 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.

Afin de construire un fantôme réaliste, les effets de volumes partiels ont été 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 (matières grise et blanche, liquide céphalo-rachidien, graisse, muscles, crâne, air,...). Au sein de chaque volume, l'intensité d'un pixel représente sa fraction pour le tissu correspondant.

3. 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 des 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. L'étape suivante consiste à définir les niveaux de gris de chaque pixel afin de compléter la simulation.

4. Simulations :

Les niveaux de gris simulés pour chaque pixel du volume ont été obtenus par résolution des équations de Bloch [Bloch 46].

Le simulateur permet la prise en compte des effets de volumes partiels, de l'inhomogénéité et du bruit.

L'intérêt du simulateur proposé sur le site BrainWeb est de pouvoir générer des images de synthèse réalistes dont il est possible de contrôler les paramètres d'épaisseur de coupe, de bruit et d'inhomogénéité.

Dans le cadre de nos expérimentations, nous avons choisi des volumes pour lesquels l'épaisseur de coupe varie de 1mm, taille couramment utilisée pour la génération d'images anatomiques, à 3mm et 5mm, tailles plutôt utilisées en IRM fonctionnelle, mais qui permettent d'accentuer l'étude des effets de volumes partiels.

Le choix du bruit proposé sur le site BrainWeb est compris entre 0% et 9%. Pour des raisons de réalisme, la valeur de 0% n'a pas été retenue. De même, la valeur de 9% produit des images à l'allure très artificielle et nous l'avons écartée. Nous avons utilisé dans nos simulations la valeur de 3%.

Les valeurs du paramètre d'inhomogénéité ont été choisies entre 0% et 20%. La valeur de 40% a été écartée car elle perturbe trop les distributions des niveaux de gris dans les images et que dans la réalité l'inhomogénéité se situe plutôt aux environs de 10%.

Image	Modalité	Epaisseur	Bruit	Inhomogénéité
Brain130	T1	1 mm	3%	0%
Brain132	T1	1 mm	3%	20 %
Brain330	T1	3 mm	3%	0%
Brain530	T1	5 mm	3%	0%

FIG. 5.2: Caractéristiques des images simulées utilisées pour la validation. Les noms des images sont associés à leurs caractéristiques d'épaisseur, de bruit et d'inhomogénéité.


Afin de valider notre approche, nous avons donc simulé quatre images ayant les caractéristiques présentées dans le tableau 5.2, et illustrées dans la figure 5.3.

Dans les volumes simulés où l'épaisseur de coupe est 1mm, la coupe située au niveau de l'axe CA-CP porte le numéro 67. Pour les images où l'épaisseur de coupe est de 3mm, la coupe correspondant à cet axe a le numéro 22 et pour les épaisseurs de 5mm, le numéro est 13.


5.2 Mesures d'évaluation

5.2.1 Cas des régions


L'utilisation d'images de synthèse pour valider notre approche permet de comparer la segmentation obtenue à une carte de référence parfaitement connue.




(a) Segmentation de référence
(Coupe 67)



(b) Image simulée Brain130
(Coupe 67)



(c) Image simulée Brain330
(Coupe 22, équivalente à 67)



(d) Image simulée Brain530
(Coupe 13, équivalente à 67)

FIG. 5.3: Coupes CA-CP correspondant aux images simulées utilisées pour la validation.

Dans ces conditions il est possible de calculer les valeurs suivantes, classiquement définies pour chaque type de tissu :

1. **VP** : Vrais Positifs, pixels détectés à raison
2. **FP** : Faux Positifs, pixels détectés à tort
3. **VN** : Vrai Négatifs, pixels non détectés à raison
4. **FN** : Faux Négatifs, pixels non détectés à tort

Dans le problème que nous nous sommes posés, nous cherchons à valider la segmentation de deux tissus, la matière grise et la matière blanche, par rapport au reste de l'image que nous nommerons "Fond", indépendamment du tissu qu'il peut représenter.

Ainsi, nous distinguons les 4 valeurs précédentes pour les deux tissus étudiés : VPGris, VPBlanc, FPGris, FPBlanc,...

Pour obtenir une représentation synthétique des ces valeurs, nous avons construit la matrice de confusion (fig. 5.4) entre la segmentation obtenue et la carte de référence.

Segmentation	Référence	Gris	Blanc	Fond
Gris		VPGris	FPGris1 = FNBlanc1	FPGris2
Blanc		FNGris1 = FPBlanc1	VPBlanc	FPBlanc2
Fond		FNGris2	FNBlanc2	VPFond

FIG. 5.4: Matrice de confusion entre la carte de référence et la segmentation. Les valeurs de FP et FN ont été scindées en deux parties pour permettre leur représentation dans la matrice de confusion.

Dans celle-ci, les classes de Faux Positifs et de Faux Négatifs sont scindées en deux et vérifient les relations suivantes :

$$\begin{aligned}
 FP_{Gris} &= FP_{Gris1} + FP_{Gris2} \\
 FP_{Blanc} &= FP_{Blanc1} + FP_{Blanc2} \\
 FN_{Gris} &= FN_{Gris1} + FN_{Gris2} \\
 FN_{Blanc} &= FN_{Blanc1} + FN_{Blanc2} \\
 FP_{Gris1} &= FN_{Blanc1} \\
 FN_{Gris1} &= FP_{Blanc1}
 \end{aligned}$$

Classiquement, les mesures présentées ci-dessus sont combinées pour calculer la sensibilité (SE) et la spécificité (SP) d'une approche :

$$SE = \frac{VP}{VP + FN} \quad (5.1)$$

$$SP = \frac{VN}{VN + FN} \quad (5.2)$$

Cependant, ces mesures n'ont pas été spécifiquement destinées à valider des segmentations et nous avons préféré utiliser les coefficients décrits dans [Shufelt 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 (QP) définis respectivement par les équations (5.3), (5.4) et (5.5) :

$$BDP = \frac{VP}{VP + FN} \quad (5.3)$$

$$BF = \frac{FP}{VP} \quad (5.4)$$

$$QP = \frac{100VP}{VP + FP + FN} \quad (5.5)$$

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 surdétection de pixels n'appartenant pas au tissu recherché dans la carte de référence. Dans le cas idéal ce coefficient vaut 0.

Enfin, le Quality Percentage représente la qualité globale absolue du système de segmentation. Dans le cas idéal ce coefficient vaut 100.

Dans le cas de la validation de 2 classes de tissus, nous calculons la valeur du Building Detection Percentage et du Branching Factor successivement pour la matière grise et la matière blanche, en utilisant les coefficients définis dans la matrice de confusion (fig. 5.4). Le Quality Percentage est calculé globalement pour chaque image et ne fait pas intervenir de distinction entre matière grise et matière blanche.

5.2.2 Cas des contours

L'objectif de la validation des contours est de proposer une mesure permettant de comparer les contours obtenus par le modèle déformable aux contours reconstruits par notre processus de fusion d'informations.

Dans ce contexte, l'objectif n'est pas de fournir une mesure absolue du nombre de points contours détectés par rapport à la carte de référence car tous les contours ne sont pas recherchés.

Par exemple, la détection des contours situés le long de la scissure inter-hémisphérique n'a pas été intégrée dans les objectifs de notre approche.

Nous avons défini une mesure qui permet de quantifier, pour les pixels d'un contour donné, le sous-ensemble des pixels qui correspondent à des points frontières entre le liquide céphalo-rachidien et la matière grise dans la carte de référence.

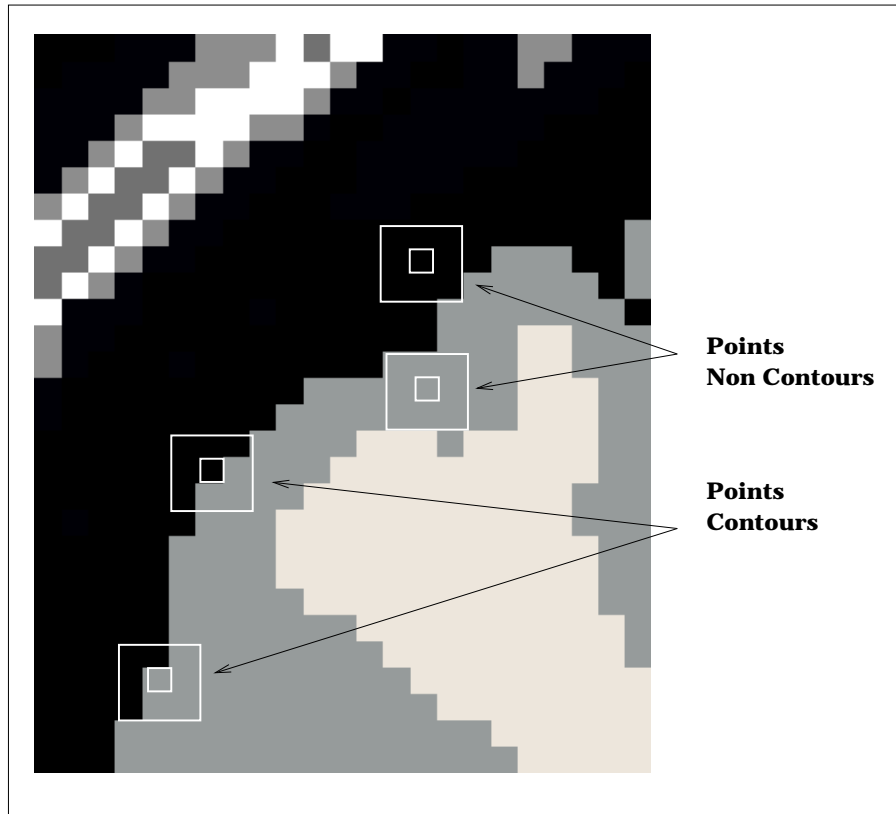


FIG. 5.5: Protocole de classification des points situés à l'interface entre liquide céphalo-rachidien et matière grise.

Le critère d'appartenance d'un pixel à un point contour a été défini de manière stricte par rapport au critère de localisation. Ainsi, un pixel de l'image résultat est considéré comme point contour si son voisinage 3x3 dans l'image de référence comporte au moins un pixel étiqueté comme matière grise et au moins un pixel étiqueté comme liquide céphalo-rachidien (voir fig. 5.5). Nous noterons $PixCont$ le nombre de pixels vérifiant ce critère pour un contour donné.

Ce critère permet de caractériser l'ensemble des pixels situés à l'interface entre matière grise et liquide céphalo-rachidien, indépendamment de leur appartenance à l'une des deux classes. Cela permet de prendre en compte les cas où le contour est sur le bord interne et les cas où il est positionné juste à l'extérieur de la région qu'il entoure.

Afin de normaliser la mesure obtenue, le nombre de pixels qualifiés de points contours est divisé par le nombre de points total du contour considéré, noté $PixTot$. Cela permet de comparer deux contours de longueurs différentes. Dans le cas idéal, la mesure vaut 1 et dans le pire des cas elle vaut 0 (aucun point du contour détecté n'appartient au contour de référence).

Ainsi, le coefficient $Proportion_{cont}$ caractérisant la proportion de pixels décrivant un point contour de la carte de référence, pour un contour en cours de validation, sera calculé selon l'équation (5.6) :

$$Proportion_{cont} = \frac{PixCont}{PixTot} \quad (5.6)$$

5.3 Evaluations

5.3.1 Protocole d'évaluation

Le protocole d'évaluation que nous avons mis en oeuvre a pour but de permettre la validation des trois principes de coopération que nous avons définis puis intégrés dans notre système de segmentation.

Pour la clarté de l'exposé, nous validerons d'abord la segmentation des régions dans le cas où l'initialisation est réalisée par le modèle déformable, puis dans le cas où le processus de rétroaction est mis en oeuvre pour transmettre le contour du cerveau de coupe en coupe en remplacement du modèle déformable.

Ensuite, nous validerons la qualité des contours détectés par le processus de fusion d'informations.

Nous avons mené sur chaque image simulée étudiée (voir 5.2), une série de trois évaluations que nous décrivons ci-dessous.

1. Evaluation de la coopération par initialisation :

Ce type d'évaluation consiste à réaliser la segmentation de coupes individuelles en utilisant le modèle déformable pour détecter le contour du cerveau et initialiser les agents de segmentation région.

La validation concerne donc dans ce cas le principe de coopération par initialisation en l'absence de rétroaction.

Théoriquement, cette validation ne devrait être effectuée qu'au niveau de coupe correspondant à l'axe CA-CP puisque le modèle déformable a été entraîné pour ce niveau.

En pratique, deux facteurs contribuent à élargir la zone de validité du modèle. Le premier facteur est lié à la continuité du contour du cerveau entre les coupes d'un volume : la topologie du contour ne varie pas et la forme générale reste globalement semblable. Ce facteur est renforcé par un second facteur lié à la capacité de déformation du modèle. Plus précisément, le modèle est conçu pour pouvoir s'adapter aux changements d'échelle grâce à un processus de recherche en multi-résolution. Par conséquent, une diminution ou une augmentation de la taille du cerveau (ce qui est observé lors de déplacements inter-coupes) a peu d'influence sur son comportement et la qualité du résultat produit.

C'est pourquoi nous pouvons envisager l'utilisation du modèle déformable pour initialiser le processus de segmentation sur plusieurs niveaux de coupes issus d'un même volume. Les résultats ainsi obtenus pourront ensuite être comparés aux segmentations obtenues sur les mêmes séries de coupes par le processus de rétroaction.

2. Evaluation de la coopération par fusion :

L'objectif de la validation des contours est de comparer les proportions respectives de pixels appartenant à l'interface matière grise/liquide céphalo-rachidien pour les contours issus du modèle déformable et les contours issus des agents contours A*.

Ce protocole a pour but d'étudier le principe de coopération par fusion et de vérifier qu'il permet un affinement des contours détectés.

3. Evaluation de la coopération par rétroaction :

Le but de cette évaluation est d'étudier le comportement du système lorsque le modèle déformable n'est utilisé qu'au niveau de l'axe CA-CP puis que les contours successivement détectés par les agents contours A* sont transmis aux coupes adjacentes dans le volume.

Dans ce qui suit, nous présentons les expérimentations que nous avons réalisées pour évaluer ces trois principes de coopération. Dans chaque cas, les images simulées Brain130, Brain132, Brain330 et Brain530 sont étudiées.

5.3.2 Evaluation de la coopération par initialisation

L'objectif de l'évaluation de la coopération par initialisation est de mesurer la qualité des résultats de segmentation en régions obtenue grâce aux agents régions spécialisés (matière grise

et matière blanche).

Dans le cadre de nos expérimentations, nous avons sélectionné pour chaque volume un ensemble de coupes adjacentes, situées au-dessus de l'axe CA-CP. La première coupe considérée est à chaque fois celle située au niveau de l'axe CA-CP.

Le cas des coupes situées au-dessous de cet axe a été considéré, mais la présence d'autres organes, comme par exemple le tronc cérébral, perturbe le fonctionnement de notre système et nécessiterait l'introduction d'autres modèles de connaissance ou de contours déformables pour produire des résultats tout à fait valides.

Chaque étape unitaire d'une évaluation consiste à segmenter une coupe en utilisant le modèle déformable pour initialiser les agents régions, puis à calculer les coefficients d'évaluation BDP, BF et QP.

Nous présentons dans les figures 5.6, 5.7, 5.8, 5.9 les matrices de confusion obtenues pour la segmentation de la coupe CA-CP dans les différents volumes simulés, et dans les figures 5.10, 5.11, 5.12, 5.13 les résultats obtenus pour des ensembles de coupes issus des volumes simulés.

	Référence	Gris (%)	Blanc (%)	Fond (%)
Segmentation				
Gris		22.79	0.41	0.44
Blanc		0.96	19.59	0.01
Fond		1.12	0.31	54.32

FIG. 5.6: Matrice de confusion entre la carte de référence et la segmentation pour la coupe 67 de l'image Brain130.

	Référence	Gris (%)	Blanc (%)	Fond (%)
Segmentation				
Gris		23.16	1.11	0.48
Blanc		0.69	19.05	0.01
Fond		1.02	0.16	54.28

FIG. 5.7: Matrice de confusion entre la carte de référence et la segmentation pour la coupe 67 de l'image Brain132.

L'étude des résultats obtenus pour un volume donné fait apparaître une grande stabilité des coefficients de mesure. Cependant, un certain nombre d'observations peuvent être effectuées au vu des résultats. Nous abordons 3 points concernant les valeurs de BDP, BF puis QP.

Segmentation	Référence	Gris (%)	Blanc (%)	Fond (%)
Gris		21.43	2.60	0.92
Blanc		1.95	17.64	0.02
Fond		1.49	0.07	53.83

FIG. 5.8: Matrice de confusion entre la carte de référence et la segmentation pour la coupe 22 de l'image Brain330.

Segmentation	Référence	Gris (%)	Blanc (%)	Fond (%)
Gris		19.00	5.44	2.30
Blanc		1.37	17.05	0.07
Fond		1.99	0.01	52.72

FIG. 5.9: Matrice de confusion entre la carte de référence et la segmentation pour la coupe 14 de l'image Brain530.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
67	0.03	0.91	0.05	0.96	96.71
68	0.05	0,92	0.05	0.96	96.87
69	0.08	0,92	0.01	0.92	95.94
70	0.08	0,90	0.01	0.92	95.47
71	0.12	0,96	0.01	0.93	96.42
72	0.11	0,96	0.01	0.92	96.30
73	0.12	0,97	0.01	0.92	96.43
74	0.10	0,96	0.02	0.94	96.64
75	0.11	0,96	0.02	0.93	96.40
76	0.12	0,96	0.02	0.94	96.23
77	0.11	0,95	0.02	0.94	96.17
Moyenne	0.09	0.94	0.02	0.93	96.32
Ecart-type	0.02	0.02	0.01	0.02	0.36

FIG. 5.10: Evaluations de la segmentation sur 11 coupes successives du volume Brain130, avec utilisation du modèle déformable pour initialiser les agents région.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
67	0.06	0.93	0.03	0.93	96.50
68	0.09	0.95	0.03	0.92	96.45
69	0.10	0.95	0.03	0.93	96.26
70	0.11	0.95	0.02	0.92	96.33
71	0.11	0.95	0.02	0.93	96.25
72	0.13	0.95	0.02	0.92	95.97
73	0.13	0.95	0.03	0.93	96.05
74	0.12	0.95	0.03	0.93	96.16
75	0.11	0.94	0.03	0.93	96.06
76	0.12	0.93	0.05	0.94	95.58
77	0.13	0.94	0.03	0.93	95.35
Moyenne	0.11	0.94	0.03	0.92	96.08
Ecart-type	0.02	0.009	0.007	0.01	0.42

FIG. 5.11: Evaluations de la segmentation sur 11 coupes successives du volume Brain132, avec utilisation du modèle déformable pour initialiser les agents région.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
22	0.16	0.86	0.11	0.86	92.91
23	0.25	0.90	0.06	0.84	92.32
24	0.28	0.89	0.07	0.83	92.03
25	0.21	0.89	0.10	0.89	93.04
26	0.22	0.90	0.09	0.88	92.68
27	0.25	0.90	0.07	0.85	92.41
28	0.28	0.90	0.07	0.84	92.41
29	0.28	0.91	0.04	0.86	93.05
Moyenne	0.24	0.89	0.07	0.85	92.60
Ecart-type	0.04	0.01	0.02	0.02	0.34

FIG. 5.12: Evaluations de la segmentation sur 8 coupes successives du volume Brain330, avec utilisation du modèle déformable pour initialiser les agents région.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
14	0.40	0.84	0.08	0.75	88.78
15	0.32	0.82	0.22	0.83	89.30
16	0.37	0.84	0.15	0.78	88.94
17	0.44	0.87	0.10	0.76	89.50
18	0.59	0.88	0.06	0.79	89.50
19	0.48	0.85	0.09	0.80	90.19
20	0.41	0.82	0.11	0.80	90.68
Moyenne	0.43	0.84	0.11	0.78	89.55
Ecart-type	0.08	0.02	0.05	0.007	0.62

FIG. 5.13: Evaluations de la segmentation sur 7 coupes successives du volume Brain530, avec utilisation du modèle déformable pour initialiser les agents région.

Le premier point que l'on peut noter est la similarité des résultats obtenus pour les valeurs du BDP Gris et du BDP Blanc. Pour toutes les images, la différence entre les valeurs moyennes de ces coefficients est inférieure à 0.04.

La similarité des résultats correspond à une similarité de la spécificité de la segmentation réalisée par deux classes d'agents (matière grise et matière blanche) spécialisés indépendamment.

Le comportement de segmentation des agents dans le système est donc relativement stable malgré les différences entre les méthodes utilisées pour les spécialiser.

Un second point à mentionner concerne la différence forte qui existe systématiquement entre le BF Gris et le BF Blanc. Généralement, un facteur 10 intervient entre ces deux valeurs.

La Branching Factor est un coefficient qui permet d'évaluer les sur-détections de pixels. Dans le cas de notre application, cela concerne les cas où les agents "débordent" vers d'autres régions.

Etant donné la stratégie de segmentation que nous avons adoptée, ces résultats sont analysés de la façon suivante : la segmentation de la matière grise est réalisée dans une première étape, et les agents correspondant peuvent agréger tout pixel vérifiant leurs critères d'agrégation ; la segmentation de la matière blanche est réalisée dans une seconde étape et les agents correspondant peuvent agréger tout pixel vérifiant leurs critères d'agrégation **à condition** que ceux-ci n'aient pas déjà été segmentés.

Par conséquent, les sur-détections de pixels effectuées par les agents de type matière grise correspondent *de facto* à des sous-détections pour les agents matière blanche, d'où la différence de valeurs de Branching Factor.

Le troisième point que nous mentionnerons dans l'analyse de ces résultats concerne les différences observées entre les QP pour les 4 images étudiées.

Ainsi, pour les images dont l'épaisseur de coupe est 1mm, la valeur de QP est environ 96%, pour l'image dont l'épaisseur des 3mm, QP vaut environ 92% et pour une épaisseur de 5mm QP vaut 89%.

Dans la pratique, la segmentation de coupes anatomiques est réalisée pour des épaisseurs de 1mm. L'intérêt de ces comparaisons n'est pas de montrer la qualité absolue des résultats obtenus dans le cas d'épaisseurs de 3mm ou 5mm mais plutôt de tester les limites de notre approche lorsque les effets de volumes partiels deviennent très importants.

La figure 5.14 montre les erreurs commises à l'interface entre matière grise et matière blanche lorsque les effets de volumes partiels augmentent.

Ainsi, pour les cas (a) (Image Brain130) et (b) (Image Brain132), très peu d'erreurs sont commises. Ces erreurs sont plus importantes dans le cas (c) (Image Brain330) et très importantes dans le cas (d) (Image Brain530).

Cette analyse permet de mieux expliquer les différences observées entre les différentes matrices de confusion construites pour la coupe CA-CP 5.6, 5.7, 5.8, 5.9 et en particulier l'augmentation progressive des coefficients extra-diagonaux.

5.3.3 Evaluation de la coopération par fusion

Pour chacune des quatre images simulées, le contour du cerveau a successivement été détecté par :

1. Le modèle déformable,
2. Les agents contours A^* guidés par une fonction de fusion pondérée par les paramètres $(\beta, \gamma) = (3, 1)$, donnant plus de poids à l'information de type contour.
3. Les agents contours A^* guidés par une fonction de fusion pondérée par les paramètres $(\beta, \gamma) = (1, 2)$, donnant plus de poids à l'information de type région.

A chaque coupe étudiée sont donc associées trois valeurs d'évaluation de la proportion de pixels, définie dans la section 5.2.2, qui appartiennent à un contour dans la carte de référence. (voir les courbes 5.15, 5.16, 5.17, 5.18).

Pour faciliter la visualisation des résultats, les valeurs d'évaluation issues d'un même processus de détection (par le modèle ou les contours A^*) sont reliées entre elles, bien que chaque expérience soit indépendante de la suivante.

Les courbes en trait continu (nommées 'bxxxContM') correspondent à une détection par le modèle, les courbes en pointillés correspondent à une détection par les agents contours A^* . De plus, pour les symboles 'X' (courbes 'bxxxContA') la fonction de fusion est pondérée par




FIG. 5.14: Comparaison des erreurs de classification entre les images simulées à l'interface entre matière grise et matière blanche.

$(\beta, \gamma) = (3, 1)$ et pour les symboles '*' (courbes 'bxxxContA2') la fonction de fusion est pondérée par $(\beta, \gamma) = (1, 2)$.

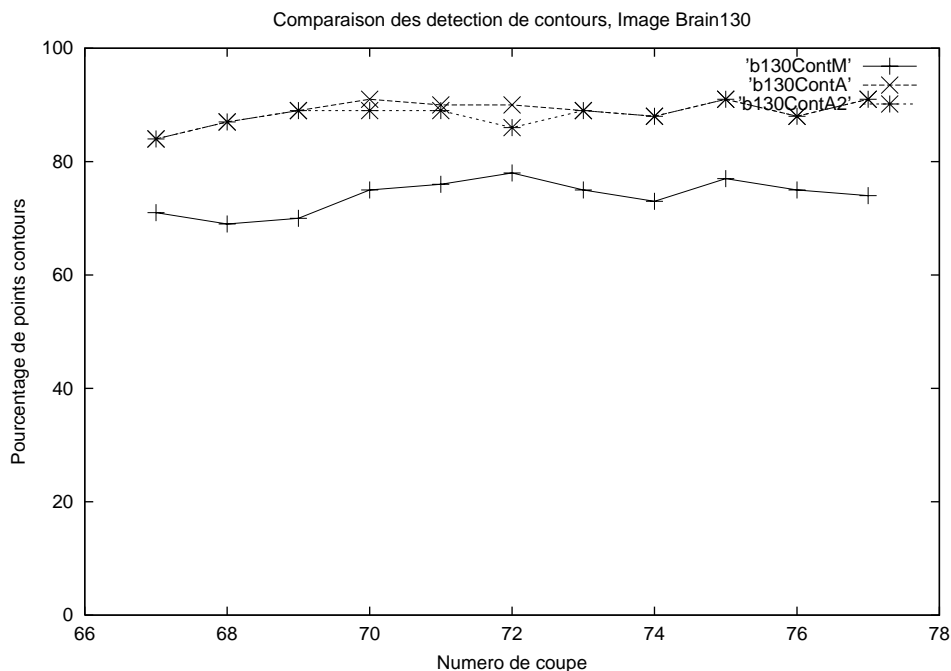


FIG. 5.15: Comparaison du pourcentage de points contours entre le modèle statistique et les agents contours A* pour l'image Brain130.

Le tableau 5.19 présente la moyenne des valeurs d'évaluation obtenue pour chaque série de coupe, et pour chaque principe de détection du contour du cerveau. Dans tous les cas, on observe que la valeur moyenne des contours détectés par les agents A* est supérieure d'au moins 11% à la valeur moyenne d'évaluation pour une détection par le modèle. Le procédé de détection par les agents A*, fondé sur de la fusion d'informations complémentaires et spatialement cohérentes permet donc un affinement du contour.

La comparaison des résultats obtenus pour les deux fonctions de fusion étudiées avantage la fonction donnant plus de poids à l'information issue du détecteur de contours pour 3 images sur 4. Cet avantage a été confirmé par nos expérimentations et la fonction de fusion finalement retenue sera pondérée par les paramètres $(\beta, \gamma) = (3, 1)$. La figure 5.20 présente les contours obtenus pour les deux fonctions de fusion.

La stabilité des courbes est en relation directe avec l'épaisseur de coupe des volumes correspondants. Ainsi, pour les images Brain130 et Brain132, le contour réel du cerveau est peu modifié entre deux coupes successives ce qui mène à des évaluations stables. Pour les images Brain 330 et Brain530, les variations du contour du cerveau sont plus importantes entre coupes




FIG. 5.16: Comparaison du pourcentage de points contours entre le modèle statistique et les agents contours A* pour l'image Brain132.




FIG. 5.17: Comparaison du pourcentage de points contours entre le modèle statistique et les agents contours A* pour l'image Brain330.

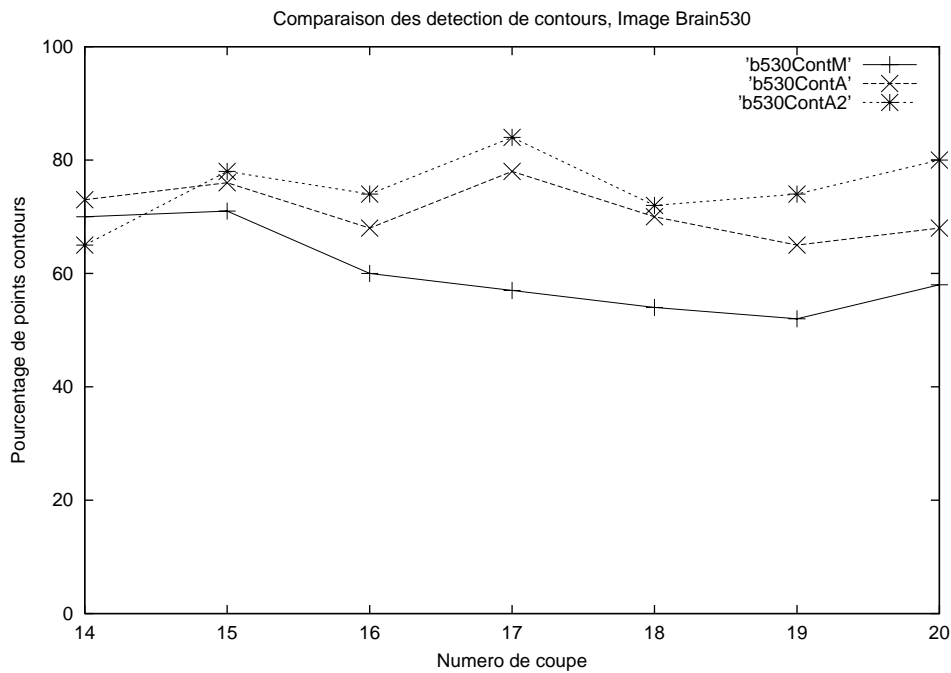


FIG. 5.18: Comparaison du pourcentage de points contours entre le modèle statistique et les agents contours A* pour l'image Brain530.

Image	Modèle	Contours A* (3,1)	Contours A* (1,2)
Brain 130	0.73 ± 0.02	0.88 ± 0.06	0.88 ± 0.05
Brain 132	0.73 ± 0.02	0.90 ± 0.01	0.88 ± 0.08
Brain 330	0.70 ± 0.03	0.82 ± 0.02	0.81 ± 0.04
Brain 530	0.60 ± 0.06	0.71 ± 0.04	0.75 ± 0.04


FIG. 5.19: Moyenne des évaluations des contours pour une série de coupes donnée et une image donnée.

successives et les valeurs d'évaluation sont par conséquent un peu moins stables.

5.3.4 Evaluation de la coopération par rétroaction

L'objectif de l'évaluation de la coopération par rétroaction est de comparer la qualité globale de la segmentation obtenue lorsque le modèle déformable est utilisé ou lorsqu'il est remplacé par la transmission des contours détectés par les agents contours A*.

Les premières expérimentations sur la rétroaction ont été menées à partir de la coupe située au niveau de l'axe CA-CP. Cependant, ce niveau de coupe présente plusieurs difficultés, comme une épaisseur de matière grise quasi nulle dans la zone postérieure du cerveau et la présence




(a) Fonction de fusion $(\beta, \gamma) = (1, 2)$



(b) Fonction de fusion $(\beta, \gamma) = (3, 1)$

FIG. 5.20: Comparaison des résultats du contour du cerveau pour deux fonctions de fusion.


d'une zone complexe comportant à la fois le lobe temporal, le lobe frontal et le lobe insulaire. Ces difficultés ont conduit à des erreurs dans la détection du contour du cerveau à l'issue de la segmentation en régions, et donc lors de la segmentation des coupes directement adjacentes par rétroaction (voir fig. 5.21).



(a) Erreur de contour



(b) Erreur sur les régions (en noir)



(c) Erreur de contour



(d) Erreur sur les régions (en noir)

FIG. 5.21: Les erreurs commises sur les contours (a) et (c) se transmettent aux régions (b) et (d).

La transmission des erreurs étant un problème difficile à corriger dans le cadre d'un processus de rétroaction, nous avons donc choisi de commencer l'évaluation à partir d'un niveau de coupe supérieur (coupe 72 dans les volumes d'épaisseur 1mm) pour lequel il n'y a pas de génération d'erreurs importantes lors de la détection des contours par les agents A*.

Les expérimentations sur la rétroaction ont été menées sur les quatre images de synthèse que nous avons construites. Pour les images Brain130 et Brain132, les coupes 72 à 77 ont été considérées et le modèle déformable a été utilisé pour initialiser la segmentation de la coupe 72 uniquement. Les autres coupes ont été segmentées en utilisant la rétroaction avec une fonction de fusion pondérée par les paramètres (3, 1).

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
72	0.12	0.96	0.01	0.93	96.30
73	0.12	0.96	0.01	0.92	96.33
74	0.11	0.95	0.01	0.93	96.25
75	0.11	0.95	0.02	0.93	96.24
76	0.10	0.95	0.02	0.94	96.19
77	0.11	0.94	0.02	0.94	96.94
Moyenne	0.11	0.95	0.015	0.93	96.39
Ecart-type	0.004	0.007	0.005	0.007	0.25

FIG. 5.22: Evaluation de la rétroaction (coupes 72 à 77) pour l'image Brain130.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
72	0.13	0.95	0.02	0.92	95.97
73	0.12	0.94	0.03	0.93	96.11
74	0.12	0.95	0.03	0.93	96.20
75	0.25	0.94	0.04	0.94	96.01
76	0.12	0.94	0.05	0.94	95.65
77	0.13	0.94	0.04	0.93	95.45
Moyenne	0.14	0.94	0.03	0.93	95.89
Ecart-type	0.04	0.005	0.01	0.007	0.26

FIG. 5.23: Evaluation de la rétroaction (coupes 72 à 77) pour l'image Brain132.

Pour l'image Brain330, la coupe de début de la rétroaction correspondant à 72 est la coupe 24. Pour l'image Brain530, la rétroaction a été effectuée à partir de la coupe 14 (équivalente à la coupe 72 dans le volume d'épaisseur 1mm).

Les figures 5.22, 5.23, 5.24, 5.25 présentent les mesures d'évaluation obtenues dans le contexte de la rétroaction. Les remarques sur les coefficients BF, BDP et QP effectuées pour la coopération par initialisation restent valables.

En considérant que dans le cadre de cette rétroaction le modèle reste valide en 2.5D, on dispose d'un critère de référence. Nous avons calculé dans les tableaux 5.26, 5.27, 5.28, 5.29 les écarts de QP entre une évaluation sans rétroaction et une évaluation avec rétroaction. Les valeurs obtenues sont toujours inférieures à 1%, ce qui permet de dire que la transmission d'informations via notre processus de rétroaction conserve la qualité de l'information.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
25	0.22	0.88	0.10	0.88	92.44
26	0.22	0.90	0.08	0.87	92.60
27	0.26	0.92	0.07	0.85	92.48
28	0.29	0.92	0.05	0.84	92.62
29	0.29	0.92	0.04	0.86	93.09
Moyenne	0.25	0.90	0.06	0.86	92.64
Ecart-type	0.03	0.01	0.02	0.01	0.23

FIG. 5.24: Evaluation de la rétroaction (coupes 25 à 29) pour l'image Brain330.

Coupe	BF Gris	BDP Gris	BF Blanc	BDP Blanc	QP (%)
14	0.40	0.84	0.08	0.75	88.78
15	0.32	0.82	0.22	0.83	89.30
16	0.37	0.86	0.15	0.79	89.26
17	0.43	0.86	0.12	0.78	89.48
18	0.59	0.89	0.07	0.79	89.52
19	0.48	0.86	0.10	0.81	90.37
20	0.40	0.83	0.11	0.80	90.97
Moyenne	0.42	0.85	0.12	0.79	89.66
Ecart-type	0.08	0.01	0.04	0.02	0.60

FIG. 5.25: Evaluation d'une série de rétroaction pour l'image Brain530.

Coupe	72	73	74	75	76	77
Ecart des QP (%)	0	0.1	0.39	0.16	0.04	0.23

FIG. 5.26: Ecarts en valeur absolue entre les Quality Percentage obtenus avec rétroaction et sans rétroaction, image Brain130.

Coupe	72	73	74	75	76	77
Ecart des QP (%)	0	0.18	0.73	0.72	0.51	0.65

FIG. 5.27: Ecarts en valeur absolue entre les Quality Percentage obtenus avec rétroaction et sans rétroaction, image Brain132.

Coupe	24	25	26	27	28	29
Ecart des QP	0 (%)	0.6	0.08	0.07	0.21	0.04

FIG. 5.28: Ecarts en valeur absolue entre les Quality Percentage obtenus avec rétroaction et sans rétroaction, image Brain330.


Coupe	14	15	16	17	18	19	20
Ecart des QP	0 (%)	0	0.32	0.02	0.02	0.18	0.19

FIG. 5.29: Ecarts en valeur absolu entre les Quality Percentage obtenus avec rétroaction et sans rétroaction, image Brain530.


5.4 Segmentation d'images réelles

Les tableaux 5.30 et 5.31 présentent des exemples de segmentation réalisées par les agents matière grise et matière blanche dans le cadre des contraintes définies dans cette partie.


Les figures 5.32 et 5.33 présentent les résultats du processus de rétroaction pour la segmentation de plusieurs coupes situées autour de l'axe CA-CP. La rétroaction est initialisée sur la coupe 36 puis propagée soit vers le bas (coupes 35, 34, 33), soit vers le haut (coupes 37 à 44).




(a) Image source1




(b) Résultat de segmentation1




(c) Image source2



(d) Résultat de segmentation2




(e) Image source3




(f) Résultat de segmentation3


FIG. 5.30: (a) (c) et (e) : Images sources. (b) (d) et (f) Résultats de segmentation



(a) Image source4




(b) Résultat de segmentation4



(c) Image source5



(d) Résultat de segmentation5



(e) Image source6



(f) Résultat de segmentation6

FIG. 5.31: (a) (c) et (e) : Images sources. (b) (d) et (f) Résultats de segmentation

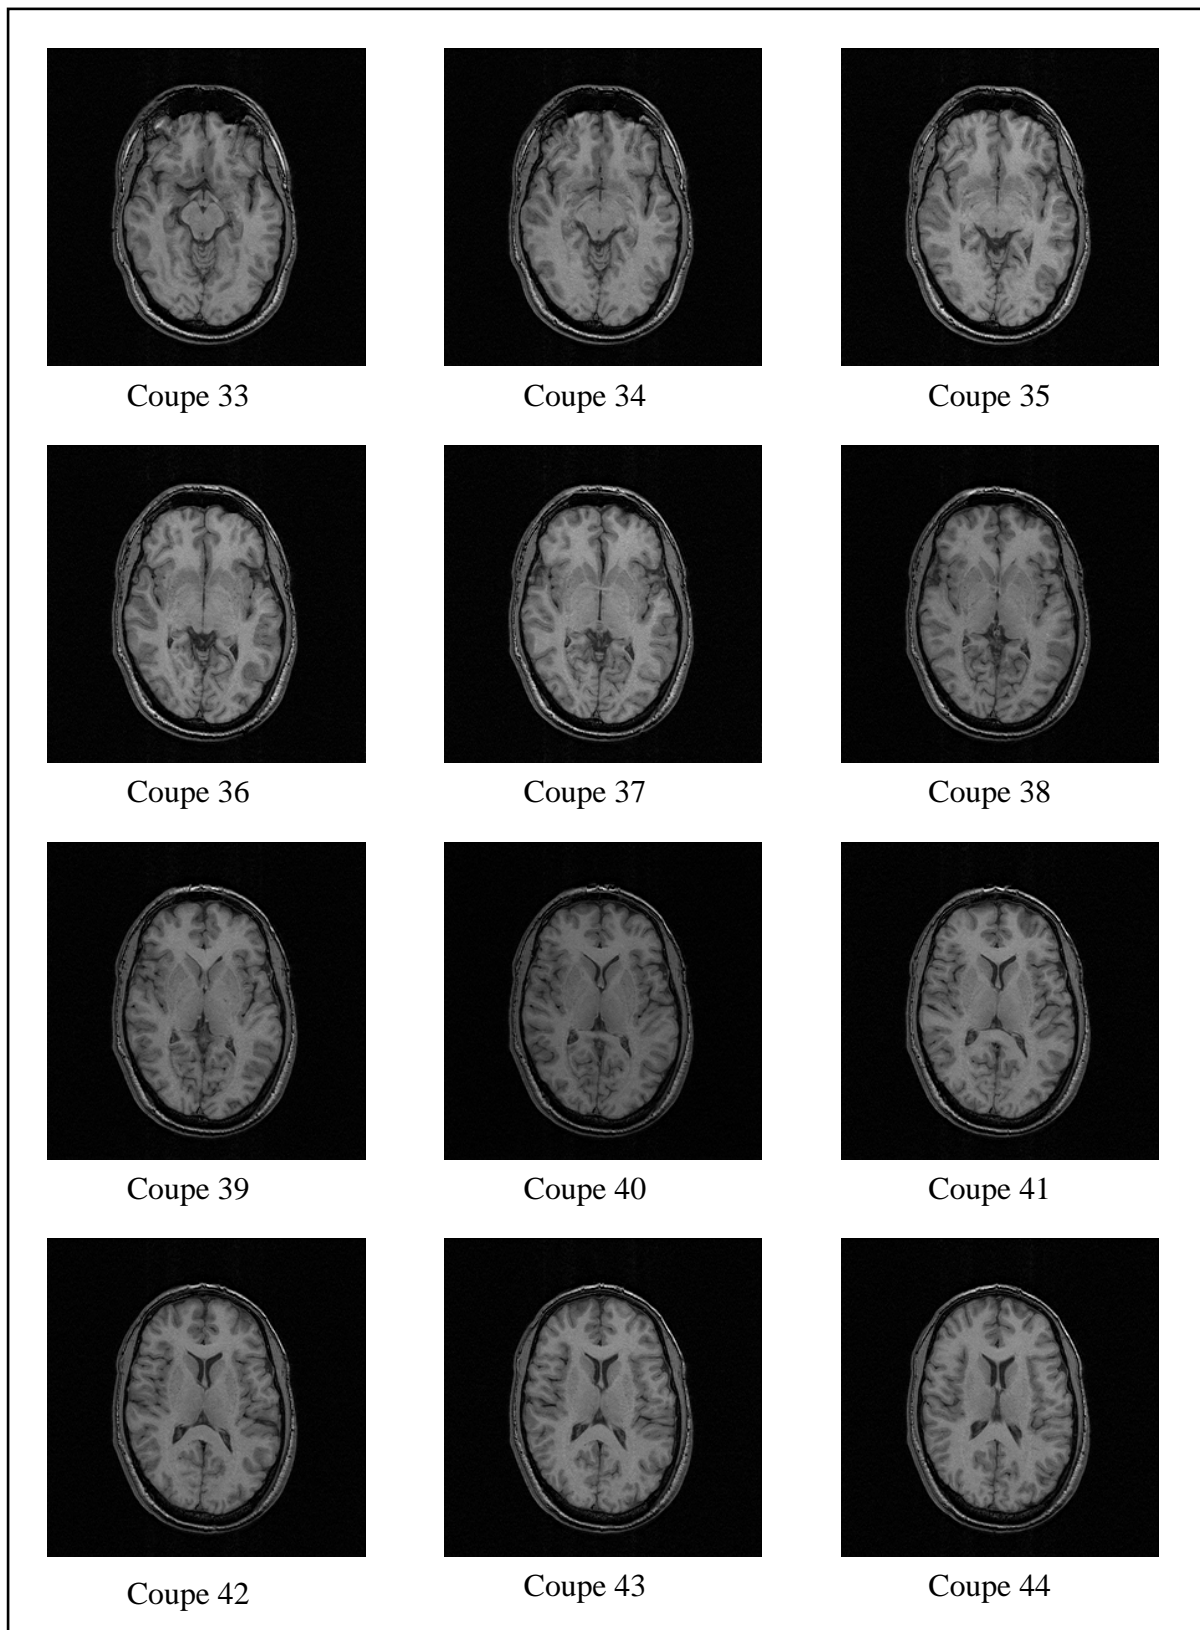


FIG. 5.32: Ensemble de coupes adjacentes d'un volume IRM.

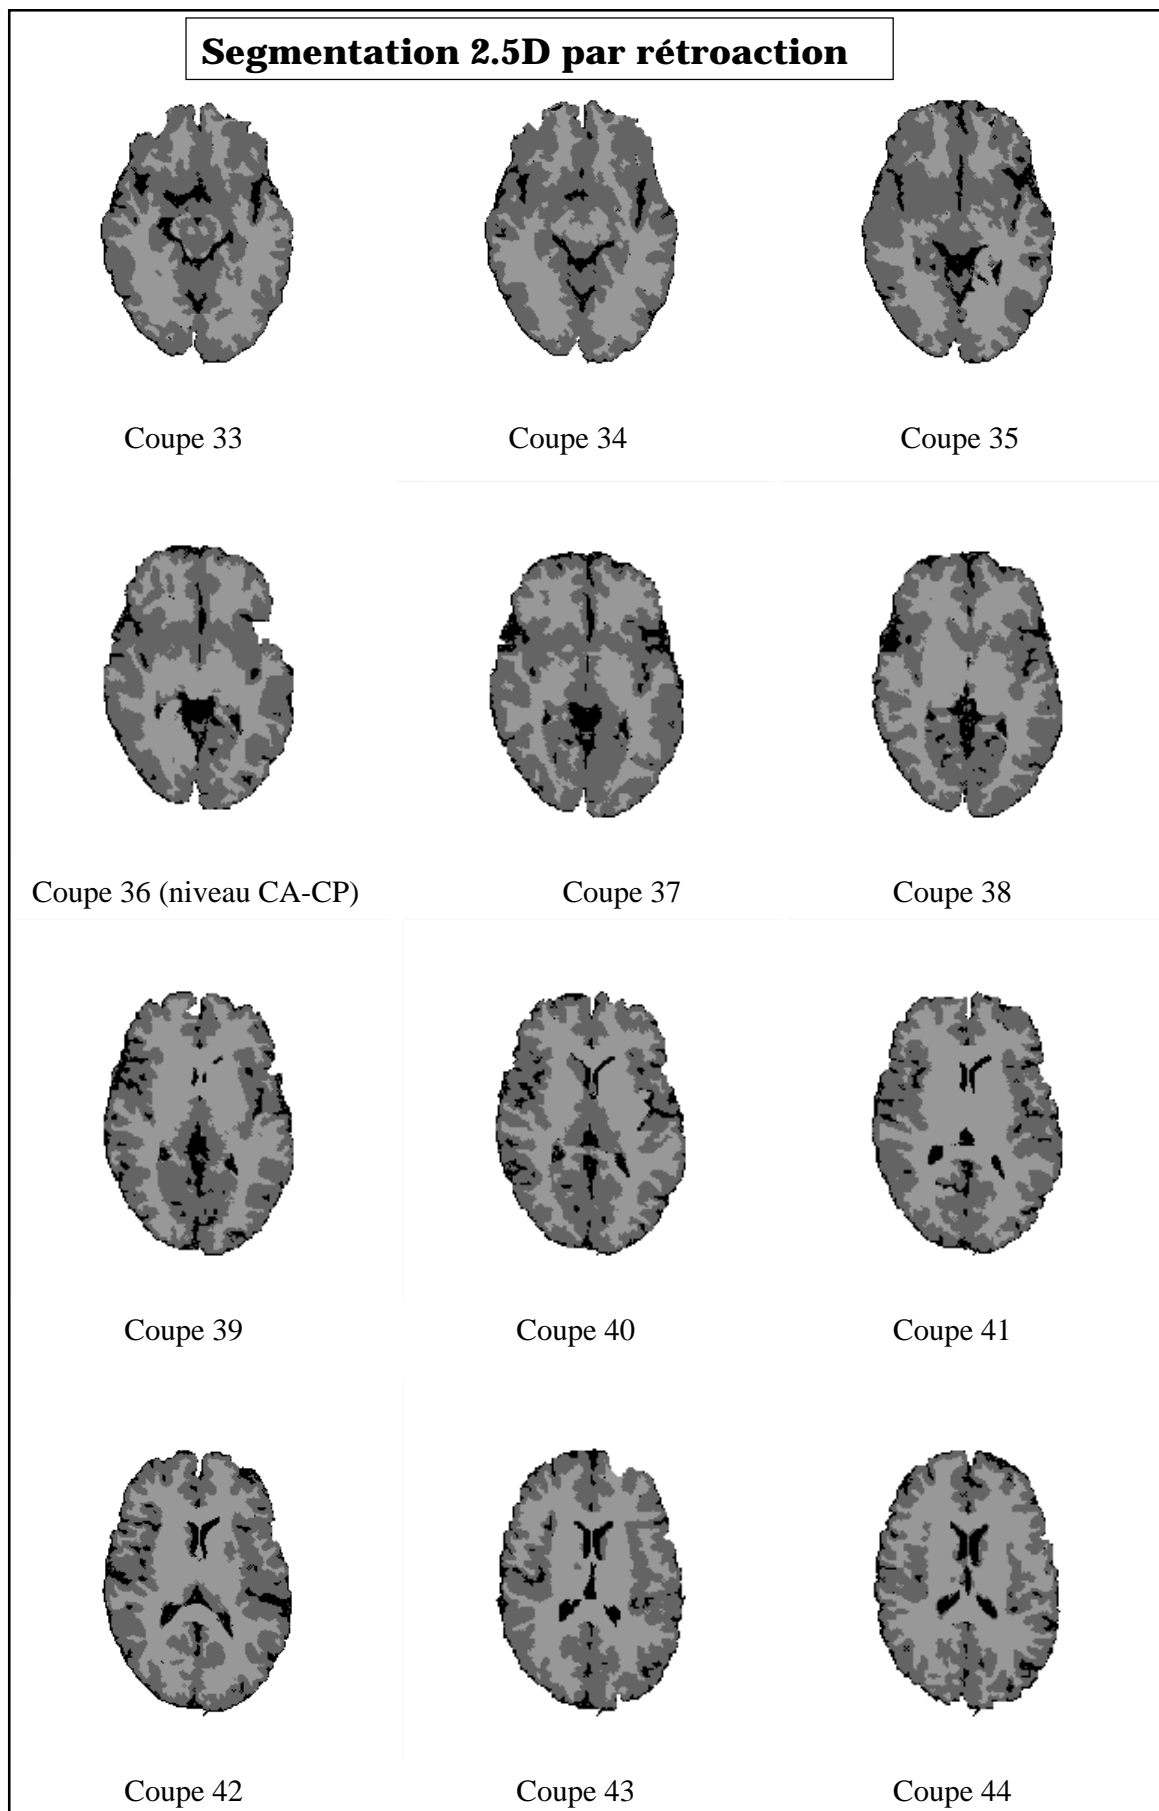


FIG. 5.33: Segmentation par rétroaction à partir de la coupe 36 des coupes inférieures et supérieures.

Conclusion

L'utilisation d'images de synthèse nous a permis, au cours de ce chapitre, d'évaluer quantitativement les différents aspects de notre approche.

Nous avons ainsi montré que les agents de type région ont des comportements similaires malgré l'utilisation de processus de spécialisation différents, mais que l'ordre de segmentation des tissus influence leurs taux de sous-détection ou sur-détection.

Les évaluations des contours ont permis de choisir une pondération pour la fonction de fusion utilisée pour guider les agents A*. Cette pondération donne plus de poids à une source d'information non interprétée et indépendante de traitements antérieurs, ce qui évite la transmission d'informations erronées.

Enfin, le coefficient global de qualité de notre approche est de 96% pour les coupes d'épaisseur 1mm.

Quels que soient les objectifs recherchés, il est toujours souhaitable d'obtenir les meilleurs résultats possibles. Par exemple, dans le cadre d'applications sur la neuro-dégénérescence, l'évolution des volumes de tissus est étudiée au cours du temps et les variations entre acquisitions sont généralement très faibles, ce qui nécessite une grande précision de la segmentation.

Dans un objectif de mise en correspondance des segmentations avec des IRM fonctionnelles, il est également nécessaire d'avoir la meilleure précision pour mettre en correspondance la segmentation avec des acquisitions décrivant les activités fonctionnelles (pour lesquelles 1 pixel vaut environ 4mm, au lieu de 1mm dans les images anatomiques).

Conclusion générale

L'étude bibliographique menée au chapitre 2 a montré la diversité des approches qui existent pour aborder la segmentation des images de résonance magnétique cérébrales. A plusieurs reprises au cours de ce document, nous avons envisagé cette diversité sous un angle de complémentarité plutôt que d'opposition et l'ensemble du travail que nous avons réalisé au cours de cette thèse est fondé sur l'exploitation d'informations variées issues de trois approches conceptuellement très différentes.

Ainsi, nous avons commencé par apprendre à reconnaître et détecter le contour du cerveau au cours d'un processus d'apprentissage interactif, ce qui a permis la construction d'un modèle statistique déformable de ce contour.

L'utilisation d'un tel modèle peut être une fin en soi si l'objectif de l'utilisateur est de détecter un contour dans une coupe quelconque. Cependant, le contour détecté par le modèle est aussi un précieux vecteur de connaissance dans la mesure où le contour fourni n'est pas seulement un contour mais le contour du cerveau, et où cette information peut être exploitée pour guider une approche ayant des objectifs complémentaires.

La complémentarité naturelle de la détection du contour du cerveau est la segmentation des tissus qui le constituent. C'est grâce à la connaissance transmise par le modèle déformable que des contraintes spatiales peuvent être définies automatiquement. Ces contraintes sont ensuite exploitées pour spécialiser localement des agents de segmentation en régions de type matière grise puis matière blanche.

L'ensemble du processus de spécialisation des agents correspond au cadre de la coopération par initialisation que nous avons défini dans la partie 4.1.

Les résultats fournis par la segmentation en régions permettent d'obtenir une information plus précise sur le contour du cerveau que ce qu'il est possible de modéliser. Cependant, la segmentation est le résultat d'un processus de détection contraint et peut comporter des erreurs. De plus, la topologie de la frontière des régions de matière grise n'est pas nécessairement celle d'un contour fermé.

C'est dans le but d'affiner le contour du cerveau, tout en s'appuyant sur le résultat de la

segmentation en régions et en conservant une topologie de contour fermé, qu'une troisième approche indépendante a été introduite dans notre système.

Ainsi, un détecteur de contours fondé sur une interpolation du signal discret a été utilisé pour générer une information indépendante sur la localisation précise des contours recherchés.

Le cadre de la coopération par fusion d'informations présenté dans la partie 4.2 a permis de combiner l'information issue de la segmentation en régions avec l'information issue du détecteur de contours pour guider une nouvelle détection plus fine du contour du cerveau.

Finalement, l'obtention d'un contour plus précis, ayant la même topologie que celle du modèle déformable initialement utilisé a permis d'envisager une rétroaction (partie 4.3) sur le processus complet de segmentation.

L'intérêt principal de la rétroaction est qu'elle permet, étant donné la continuité du contour du cerveau en 3D, une transmission d'information de coupe en coupe et par conséquent une segmentation en 2.5D.

Notre processus de segmentation fait donc intervenir, à différents niveaux, des sources d'information complémentaires et indépendantes. Leur combinaison dans trois cadres de coopération permet d'aboutir à un résultat plus complet que ce que chacune des approches utilisées aurait pu produire indépendamment. Un des intérêts de ce principe de segmentation est qu'il permet de représenter une partie des connaissances explicitement, alors que celles-ci sont masquées dans d'autres systèmes de segmentation.

Sur le plan méthodologique, l'approche que nous avons développée permet la génération automatique de contraintes et le système qui en résulte est caractérisé par une grande capacité d'adaptativité et d'autonomie.

Cependant, le contrôle du système est surtout fondé sur un contrôle par lancement de méthodes et il serait intéressant de pouvoir disposer de moyens de contrôle *a posteriori* en fonction des comportements observés. Cela pourrait être envisagé dans un cadre de surveillance mutuelle des agents entre eux, à condition de disposer de critères d'évaluation de la qualité des résultats fournis.

L'approche que nous avons proposée admet aussi des limites et nous avons constaté trois principaux problèmes lors de nos recherches. Ceux-ci concernent les effets de volume partiels, la détection fine des sillons corticaux et l'aspect tri-dimensionnel de la segmentation. Nous présentons ci-dessous, les perspectives qui pourraient être envisagées en réponse à ces difficultés dans le cadre de futurs travaux.

La prise en compte des effets de volumes partiels est un problème qu'il serait intéressant de

considérer dans un contexte de coopération entre agents de segmentation. Une des difficultés résidant dans un tel travail serait la mise en place de protocoles de communication entre agents, problème encore peu résolu dans l'ensemble des systèmes multi-agents.

Une autre difficulté serait, dans le cadre de la rediscussion des affectations de pixels entre deux agents, de définir une mesure d'évaluation commune de la qualité relative d'un pixel par rapport à une région. En effet, si chaque agent peut évaluer un pixel selon ses propres critères, il n'est pas évident de définir des critères permettant d'obtenir des valeurs d'évaluation comparables. Or l'existence de telles mesures est une condition indispensable à la génération de processus de réaffectation de pixels.

La détection des sillons corticaux est un domaine de recherche en soi et de nombreuses références y sont consacrées [Davatzikos 97], [Le Goualher 99], [Sandor 97], [Thompson 96], [Mangin 95],[Royackkers 98],...

Un des objectifs initiaux du processus d'affinement du contour du cerveau était de permettre la détection simultanée des sillons et du bord externe du cerveau. A l'issue des expérimentations, il est apparu que ces deux objectifs n'étaient pas compatibles dans le contexte d'une détection par des agents fondés sur des principes de programmation dynamique.

Nous avons donc choisi de séparer ces deux objectifs et d'envisager la détection des sillons au moyen d'agents contours spécialisés pour la résolution de ce problème. L'idée serait de générer des agents contours exploitant à la fois une information de type contour et une information sur la distance à la frontière entre les tissus matière grise et matière blanche. Le principe de l'exploitation de l'axe médian a été introduit dans [Lohmann 98], mais les erreurs de segmentations de la matière blanche ne pouvaient être contrôlées. Une telle problématique rejoint celle que nous avons eue pour l'affinement du contour du cerveau et pourrait donc être envisagée dans un cadre de fusion d'informations.

La principale difficulté que nous avons rencontrée pour l'extension de notre approche en 3D est qu'il n'est pas encore possible de construire un modèle tri-dimensionnel du contour du cerveau. Une telle construction nécessite en effet la mise en oeuvre de processus automatiques de repérage de points d'intérêts dans des volumes, de processus de mise en correspondance d'ensemble de points entre plusieurs volumes, tout en vérifiant des contraintes topologiques,...

Cependant, si un tel modèle était disponible, il serait envisageable de développer de nouveaux modèles d'agents spécialisés pour réaliser directement la segmentation en 3D.

L'affinement des contours serait remplacé par un affinement de surface et il est probable que la programmation dynamique serait remplacée par un autre outil algorithmique pour des raisons de complexité des calculs.

Enfin, une perspective indépendante des difficultés rencontrées au cours de ces recherches est l'intégration prochaine de ce travail dans le système de dépliage du cortex, développé

actuellement par l'équipe du Pr. Segebarth (INSERM U438), dans le cadre d'études en IRM fonctionnelle.

Bibliographie

- [Afia 97] Dossier Intelligence Artificielle Distribuée, Systèmes Multi-Agents. *Bulletin de l'Association Française pour l'intelligence Artificielle*, 28, pp. 23–54, 1997.
- [Alaux 94] A. Alaux. *L'image par résonance magnétique*. Montpellier, Sauramps Medical, 1994.
- [Atkins 98] M.S. Atkins and B.T. Mackiewich. Fully Automatic Segmentation of the Brain in MRI. *IEEE Transactions on Medical Imaging*, 17(1), pp. 98–107, 1998.
- [Bardinet 95] E. Bardinet, L. Cohen, and N. Ayache. A parametric deformable model to fit unstructured 3D data. Technical Report 2617, INRIA Sophia Antipolis, 1995.
- [Barillot 97] B.Gibaud, C. Garlatti, C. Barillot, and E. Faure. Methodology for the design of digital brain atlases. *Artificial Intelligence in Medecine, Europe, Grenoble, Lecture Notes in Artificial Intelligence*, 12(11), 1997.
- [Barillot 98] C. Barillot, B.Gibaud, G. Le Goualher, and X. Morandi. Représentation mixte numérique/ symbolique des sillons corticaux. In *Proceedings of 11e congrès Reconnaissance des Formes et Intelligence Artificielle*, 165–174, 1998.
- [Barret 97] W. A. Barrett and E.Mortensen. Interactive live-wire boundary extraction. *Medical Image Analysis*, 1(4), pp. 331–341, 1996-97.
- [Bellet 95] F. Bellet, J.M. Salotti, and C. Garbay. Une approche opportuniste et coopérative pour la vision de bas niveau. *Traitement du Signal*, 12(5), pp. 479–494, 1995.
- [Besag 74] J. Besag. Spatial Interaction and the statistical Analysis of Lattice Systems. *Journal of Royal Statistics Society*, 36(2), pp. 192–225, 1974.
- [Bezdek 93] J.C. Bezdek, L.O. Hall, and L.P. Clarke. Review of MR segmentation techniques using pattern recognition. *Medical Physics*, 20(4), pp. 1033–1048, 1993.

- [Bittoun 98] J. Bittoun. Basic Principles of Magnetic Resonance Imaging. In *15th Annual Scientific Meeting of the European Society for Magnetic Resonance in Medicine and Biology*, 45–53. Eds Cerdan, Haase and Terrier. Geneva. Springer, 1998.
- [Bloch 46] F. Bloch. Nuclear Induction. *Physics Review*, 70, pp. 460, 1946.
- [Bloch 96] I. Bloch. Information Combination Operators for Data Fusion : A comparative Review with Classification. *IEEE Trans. on systems, man and cybernetics-Part A : Systems and Humans*, 26(1), pp. 52–67, 1996.
- [Boucher 98] A. Boucher, A. Doisy, X. Ronot, and C. Garbay. A society of goal-oriented agents for the analysis of living cells. *Artificial Intelligence in Medicine*, 14, pp. 183–199, 1998.
- [Bozma 92] I. Bozma and J.S. Duncan. Modular system for image analysis using a game-theoretic framework. *Image and Vision Computing*, 10(6), pp. 431–443, 1992.
- [Bozma 94] 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, 1994.
- [Brooks 91] R. A. Brooks. Intelligence without representation. *Artificial Intelligence*, 47, pp. 139–159, 1991.
- [Brumer 91] M.E. Brummer, R.L. Eisner, R.M. Mersereau, and R.R.J. Lewine. Automatic detection of brain contours in MRI data sets. *12th conference IPMI91 Proceedings*, 1991.
- [Canny 86] J.F. Canny. A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8, pp. 679–697, 1986.
- [Caselles 92] V. Caselles, F. Catte, T. Coll, and F. Dibos. A geometric model for active contours in image processing. *Technical Report 9210, CEREMADE*, 1992.
- [Castan 90] S. Castan, J. Zhao, and J. Shen. Optimal filter for edge detection methods and results. In *ECCV 90, Lecture Notes in Computer Science*, 13–17. O. Faugeras Ed., Springer Verlag, 1990.
- [Chakraborty 99] A. Chakraborty and J.S. Duncan. Game Theoretic Integration for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(1), pp. 12–30, 1999.
- [Chehikian 97] A. Chehikian. Filtrés récursifs pour l'estimation du gradient et de la détection des contours par interpolation splines. *Traitement du Signal*, 14(1), pp. –, 1997.

- [Chiou 95] G. Chiou and J.N. Hwang. A Neural Network-Based Stochastic Active Contour Model (NNS-SNAKE) for Contour Finding of Distinct Features. *IEEE Transactions on Image Processing*, 4(10), pp. 1407–1416, 1995.
- [Chun 96] S. Chun Zhu and A. Yuille. Region Competition : Unifying Snakes, Region Growing and Bayes/MDL for Multiband Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(9), pp. 884–890, 1996.
- [Clarke 95] L.P. Clarke, R.P. Velthuizen, M.A. Camacho, J.J. Heine, and al. MRI segmentation : methods and applications. *Magnetic Resonance Imaging*, 13(3), pp. 343–368, 1995.
- [Cocquerez 95] J.-P. Cocquerez and S. Philipp. *Analyse d'images : filtrage et segmentation*. Masson, 1995.
- [Cohen 93] L.D. Cohen and I. Cohen. Finite-Element Methods for Active Contour Models and Balloons for 2-D and 3-D Images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11), pp. 1131–1147, 1993.
- [Collins 95] D.L. Collins, A.C. Evans, C. Holmes, and T.M. Peters. Automatic 3D segmentation of neuro-anatomical structures from MRI. In *Information Processing in Medical Imaging*, 139–152. Kluwer Academic Publishers, 1995.
- [Collins 98] D.L. Collins, A.P. Zijdenbos, V. Kollokian, J.G. Sled, N.J. Kabani, C.J. Holmes, and A.C. Evans. Design and construction of a realistic Digital brain phantom. *IEEE Transactions on Medical Imaging*, 17(3), pp. 463–468, 1998.
- [Cootes 95] T.F. Cootes, C.J. Taylor, D.H. Cooper, and J. Graham. Active Shape Models-Their Training and Application. *Computer Vision and Image Understanding*, 61(1), pp. 38–59, January 1995.
- [Davatzikos 95] C. Davatzikos and J.L. Prince. An active contour model for mapping the cortex. *IEEE Transactions on Medical Imaging*, 14(1), pp. 65–80, 1995.
- [Davatzikos 97] M. Vaillant and C. Davatzikos. Finding parametric representations of the cortical sulci using an active contour model. *Medical Image Analysis*, 1(4), pp. 295–315, 1996-97.
- [Dellepiane 91] S. Dellepiane, G. Venturi, and G. Vernazza. A fuzzy model for the processing and recognition of MR pathological images. In *Lecture notes in computer science, IPMI proceedings*, 444–457. Springer, 1991.
- [Deriche 87] R. Deriche. Using Canny's criteria to derive a recursively implemented optimal edge detector. *International Journal of Computer Vision*, 1, pp. 167–187, 1987.

- [Duta 98] N. Duta and M. Sonka. Segmentation and Interpretation of MR Brain Images : An Improved Active Shape Model. *IEEE Transactions on Medical Imaging*, 17(6), pp. 1049–1062, 1998.
- [Evans 93] A.C. Evans, D.L. Collins, S.R. Mills, E.D. Brown, E.D. Kelly, and T.M. Peters. 3D statistical neuroanatomical models from 305 MRI volumes. In *IEEE-nuclear science symposium and medical imaging conference*, 1813–1817, 1993.
- [Fadili 98] J. Fadili, B. Moretti, S. Ruan, and D. Bloyet. Méthode coopérative et quantification de la segmentation de l'encéphale en Imagerie par Résonance Magnétique. *Traitement du Signal*, 5(15), pp. 353–364, 1998.
- [Ferber 95] J. Ferber. *Les systmes multi-agents : vers une intelligence collective*. InterEditions, 1995.
- [Friston 89] K.J. Friston, R.E. Passingham, J.G. Nutt, J.D. Heather, G.V Sawle, and R.S.J. Frackowiak. Localisation in PET images : Direct Fitting of the Intercommisural (AC-PC) line. *Journal of cerebral Blood Flow and Metabolism*, 9, pp. 690–695, 1989.
- [Friston 95] K. J. Friston, A. P. Holmes, J. B. Poline, C. D. Frith, and R. S. J. Frackowiak. Statistical Parametric Maps in Functional Imaging : a general linear approach. *Human Brain Mapping*, 2, pp. 189–210, 1995.
- [Geman 84] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6, pp. 721–741, 1984.
- [Géraud 98] T. Géraud. Segmentation des structures internes du cerveau en imagerie par résonance magnétique 3D. *Thèse de doctorat, Télécom Paris*, 1998.
- [Germond 97] L. Germond, C. Garbay, C. Taylor, and S. Solloway. Coopération entre processus guidés par les données et processus guidés par les modèles pour la segmentation. In *16e Colloque Gretsi "Traitement du Signal et Images"*, 1997.
- [Germond 98] L. Germond. Coopération entre processus guidés par les données et les modèles pour la segmentation en IRM. Technical Report RR1005-I, TIMC-IMAG, 1998.
- [Germond 99a] L. Germond, M. Dojat, C. Garbay, and C. Taylor. Une approche coopérative pour la segmentation en IRM cérébrale. In *17e Colloque Gretsi "Traitement du Signal et Images"*, 1999.
- [Germond 99b] L. Germond, M. Dojat, C. Taylor, and C. Garbay. A multi-agent system for MRI brain segmentation. In *7th European Conference on Artificial Intelli-*

- gence and Medecine*, 423–432. Lecture Notes in Artificial Intelligence 1620, Springer, 1999.
- [Germond 99c] L. Germond, M. Dojat, C. Taylor, and C. Garbay. Un système multi-agents pour la segmentation en IRM cérébrale. In *ORASIS, Journées francophones des jeunes chercheurs en analyse d'images*, 279–288. INRIA, 1999.
- [Gong 95] L. Gong and A. Kulikowski. Composition of image Analysis Processes Through Object-centered Hierarchical Planning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(10), pp. 997–1009, 1995.
- [Held 97] K. Held, E. Rota Kops, B.J. Krause, W.M. Wells, R. Kikinis, and H.W. Muller-Gartner. Markov Random Field Segmentation of Brain MR Images. *IEEE Transactions on Medical Imaging*, 16(6), pp. 878–886, 1997.
- [Huet 99] F. Huet-Guillemot. Fusion d'images segmentées et interprétées. Application aux images aériennes. *Thèse de doctorat de l'université de Cergy-Pontoise*, 1999.
- [Jaggi 98] C. Jaggi. Segmentation par méthode markovienne de l'encéphale humain par résonance magnétique : théorie, mise en oeuvre et évaluation. *Thèse de doctorat de l'université de Caen*, 1998.
- [Johnston 96] B. Johnston, M.S. Atkins, B. Mackiewicz, and M. Anderson. Segmentation of Multiple Sclerosis Lesions in Intensity Corrected Multispectral MRI. *IEEE Transactions on Medical Imaging*, 15(2), pp. 154–169, 1996.
- [Kapur 96] T. Kapur, W. Eric, L. Grimson, W.M. Wells, and R. Kikinis. Segmentation of brain tissue from magnetic resonance images. *Medical Image Analysis*, 1(2), pp. 109–127, 1996.
- [Kass 88] M. Kass, A. Witkin, and D. Terzopoulos. Snakes : Active Contour Models. *International Journal of Computer Vision*, 1, pp. 312–331, 1988.
- [Laidlaw 98] D.H. Laidlaw, K.W. Fleisher, and A.H. Barr. Partial-Volume Bayesian Classification of Material Mixtures in MR Volume Data Using Voxel Histograms. *IEEE Transactions on Medical Imaging*, 17(1), pp. 74–86, 1998.
- [Lancaster 95] J. Lancaster, T. Glass, B. Lankipalli, H. Downs, H. Mayberg, and P. Fox. A Modality-Independent Approach to Spatial Normalisation of Tomographic Images of the Human Brain. *Human Brain Mapping*, 3, pp. 209–223, 1995.
- [Langlois 99] S. Langlois, M. Desvignes, J.M. Constans, and M. Revenu. MRI Geometric Distortions : A simple Approach to Correcting the effects of non-linear gradient fields. *Journal of Magnetic Resonance Imaging*, 9(6), pp. 821–831, 1999.
- [Le Floch 90] P. Le Floch-Prigent, M. Molho, and H. Outin. *Imagerie de l'encéphale, Anatomie et observations cliniques*. Laboratoires Sandoz, 1990.

- [Le Goualher 99] G. Le Goualher, E. Procyk, D. Collins, R. Venugopal, C. Barillot, and A. Evans. Automated extraction and variability analysis of sulcal neuroanatomy. *IEEE Transactions on Medical Imaging*, 18, pp. 206–217, 1999.
- [Lecornu 98] L.Lecornu, C. Roux, and J.J. Jacq. Suivi bilatéral des structures vasculaires dans les images d’angiographie et reconstruction 3D des branches principales du réseau vasculaire coronarien à partir de deux projections angiographiques. *Traitement du Signal*, 15(5), pp. 395–410, 1998.
- [Lee 98] C. Lee, S. Huh, T. Ketter, and M. Unser. Unsupervised connectivity-based thresholding segmentation of midsagittal brain MR images. *Computers in Biology and Medecine*, 28, pp. 309–338, 1998.
- [Li 95] H. Li, R. Declerck, B. De Cuyper, and al. Object-recognition in brain CT-scans : knowledge-based fusion of data from multiple feature extractors. *IEEE Transactions on Medical Imaging*, 14(2), pp. 212–229, 1995.
- [Lohmann 98] G. Lohmann. Extracting Line representation of Sulcal and Gyral Patterns in MR Images of the Human Brain. *IEEE Transactions on Medical Imaging*, 17(6), pp. 1040–1048, 1998.
- [Lundervold 95] A. Lundervold and G. Storvik. Segmentation of Brain Parenchyma and Cerebrospinal Fluid in Multispectral Magnetic Resonance Images. *IEEE Transactions on Medical Imaging*, 14(2), pp. 339–349, 1995.
- [Mangin 95] J.F. Mangin, J. Regis, I. Bloch, and V. Frouin. A MRF based random graph modelling the human cortical topography. In *First International Conference CVRMed, Nice*, 177–183, 1995.
- [Martelli 76] A. Martelli. An application of Heuristic Search Methods to Edge and Contour Detection. *Communications of the ACM*, 19(2), pp. 73–83, 1976.
- [Mazziota 95] J. Mazziota, A. Toga, A. Evans, P. Fox, and J. Lancaster. A probabilistic atlas of the human brain : theory and rationale for its development. *Neuroimage*, 2, pp. 89–101, 1995.
- [Mc Inerney 95] T. McInerney and D. Terzopoulos. Topologically Adaptable Snakes. In *International Conference on Computer Vision*, 840–845, 1995.
- [Mc Inerney 96] T. McInerney and D. Terzopoulos. Deformable Models in Medical Image Analysis : A Survey. *Medical Image Analysis*, 1(2), pp. 91–108, 1996.
- [Meyer 95] C.R. Meyer, P.H. Bland, and J. Pipe. Retrospective Correction of Intensity Inhomogeneities in MRI. *IEEE Transactions on Medical Imaging*, 14(1), pp. 36–41, 1995.
- [Nikou 99] C. Nikou, F. Heitz, and J.J. Armspach. A probabilistic multi-object deformable model for MR/SPECT brain image registration and segmentation.

- SPIE Proceedings of the International Conference on Medical Imaging, San Diego, California, USA*, 3361, pp. 20–26, 1999.
- [Pavlidis 90] T. Pavlidis and Y.T. Liow. Integrating region growing and edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(3), pp. 225–233, 1990.
- [Rajapakse 97] J. Rajapakse, J. Giedd, and J. Rapoport. Statistical Approach to segmentation of single-channel cerebral MR images. *IEEE Transactions on Medical Imaging*, 16, pp. 176–186, 1997.
- [Roth 96] Roth M., Decety J., Segebarth C., and al. Possible involvement of primary motor cortex in mentally simulated movement : a functional magnetic resonance imaging study. *NeuroReport*, 7, pp. 1280–1284, 1996.
- [Royackkers 98] N. Royackkers, M. Desvignes, and M. Revenu. Une méthode générale de reconnaissance de courbes 3D : application à l'identification de sillons corticaux en imagerie par résonance magnétique. *Traitement du Signal*, 15(5), pp. 365–379, 1998.
- [Sandor 97] S. Sandor and R. Leahy. Surface-Based Labeling of Cortical Anatomy Using a Deformable Atlas. *IEEE Transactions on Medical Imaging*, 16(1), pp. 41–54, 1997.
- [Shufelt 99] J.A. Shufelt. Performance Evaluation and Analysis of Monocular Building Extraction from Aerial Imagery. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(4), pp. 311–326, 1999.
- [Sled 98] J.G. Sled, A.P. Zijdenbos, and A.C. Evans. A Nonparametric Method for Automatic Correction of Intensity Nonuniformity in MRI Data. *IEEE Transactions on Medical Imaging*, 17(1), pp. 87–97, 1998.
- [Sonka 96] M. Sonka, S. Tadikonda, and A. M. Collins. Knowledge-Based Interpretation of MR brain Images. *IEEE Transactions on Medical Imaging*, 15(4), 1996.
- [Staib 92] L.H. Staib and J.S. Duncan. Boundary Finding with Parametrically Deformable Models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(11), pp. 1061–1075, 1992.
- [Szekely 96] G. Székely, C. Brechbuler A. Kelemen, and G. Gerig. Segmentation of 2D and 3D objects from MRI volumes using constrained elastic deformations of flexible Fourier contour and surface models. *Medical Image Analysis*, 1(1), pp. 19–34, 1996.
- [Talairach 57] J. Talairach and P. Tournoux. Atlas d'anatomie stéréotaxique. *Masson et Cie*, 1957.
- [Talairach 88] J. Talairach and P. Tournoux. Co-planar stereotaxic atlas of the human brain. *Georg Thieme Verlag, Stuttgart*, 1988.

- [Teo 97] P.C. Teo, G. Sapiro, and B. Wandell. Creating Connected Representations of Cortical Gray Matter for Functional MRI Visualization. *IEEE Transactions on Medical Imaging*, 16(6), pp. 852–863, 1997.
- [Thedens 95] D.R. Thedens, D.J. Skorton, and S.R. Fleagle. Methods of Graph searching in Image Sequences with applications to cardiac Magnetic Resonance Imaging. *IEEE Transactions on Medical Imaging*, 14(1), pp. 42–55, 1995.
- [Thompson 96] P. Thompson and A. W. Toga. A Surface-Based Technique for Warping Three-Dimensional Images of the Brain. *IEEE Transactions on Medical Imaging*, 15(4), pp. 402–417, 1996.
- [Vérard 97] L. Vérard, P. Allain, J.M. travère, J.C. Baron, and D. Bloyet. Fully Automatic Identification of AC and PC landmarks on Brain MRI using Scene Analysis. *IEEE Transactions on Medical Imaging*, 16(5), pp. 610–616, 1997.
- [Warfield 95] S. Warfield, J. Dengler, J. Zaers, and al. Automatic identification of gray matter structures from MRI to improve the segmentation of white matter. *Journal of Image Guided Surgery*, 1, pp. 326–338, 1995.
- [Wells 96] W.M. Wells, L. Grimson, R. Kikinis, and F.A. Jolesz. Adaptive Segmentation of MRI data. *IEEE Transactions on Medical Imaging*, 15(4), pp. 429–442, 1996.
- [Worth 98] A. J. Worth, N. Makris, J.W Meyer, V.S. Caviness, and D.N. Kennedy. Semiautomatic segmentation of brain exterior in magnetic resonance images driven by empirical procedures and anatomical knowledge. *Medical Image Analysis*, 2(4), pp. 315–324, 1998.

Annexe

Etat de l'art sur la programmation dynamique

Dès 1974, Martelli a eu l'idée d'appliquer les techniques de parcours de graphes au cas de la détection des contours. En associant une notion de coût à chaque pixel d'une image, il est en effet possible de générer des fonctions de coût et ainsi d'évaluer les qualités respectives de différents contours reliant deux pixels donnés d'une image.

La structure de données, sous forme de matrices, classiquement utilisée pour stocker les images, se prête particulièrement aisément à une mise en correspondance avec des structures de graphes. Ainsi, les pixels représentent naturellement les noeuds d'un graphe et le coût qui permet de passer d'un pixel à un autre représente le coût associé à l'arc du graphe correspondant.

Finalement, un contour de l'image correspond à un chemin dans le graphe et la recherche de contours optimaux est réalisée par la recherche de chemins optimaux dans le graphe.

Comme pour tout problème d'optimisation, le problème essentiel reste lié à la définition de la fonction de coût qu'il est souhaitable d'associer au graphe.

De plus, la complexité algorithmique liée à la recherche de chemins optimaux devient vite importante dans le cas de l'exploration d'images 2D. Il est donc nécessaire de définir quelques heuristiques pour la réduire. Bien sûr, l'utilisation d'heuristiques ne garantit pas que les solutions trouvées seront optimales, cependant, elle permet de rendre exploitables ces techniques d'optimisation en termes de temps de calcul, tout en fournissant des résultats satisfaisants.

Nous présentons ici quelques fonctions de coûts ainsi que des heuristiques proposées. Curieusement, les références bibliographiques concernent plutôt le domaine de l'angiographie ; il semble que ce type d'approche a été peu utilisé pour l'IRM cérébrale.

- Martelli [Martelli 76] propose d'utiliser une fonction de coût assez naturelle qui tient compte de la différence de niveaux de gris entre deux pixels successifs du chemin, ainsi que de la courbure du chemin.

Soit M la différence maximale entre 2 niveaux de gris observée dans l'image étudiée, et

I l'intensité d'un pixel, la première composante de la fonction de coût décrivant le lien entre 2 pixels P et Q est exprimée par l'équation (5.7) :

$$c_1(P, Q) = M - (I(P) - I(Q)) \quad (5.7)$$

La deuxième composante concerne la courbure et est liée à la recherche de contours plutôt lisses et associe un coût très élevé aux suites de 3 arcs comprenant des extrémités communes. On note c_2 ce coût.

La fonction de coût globale C est la somme (éq.5.8) :

$$C = c_1 + c_2 \quad (5.8)$$

L'heuristique proposée par Martelli pour réduire la complexité algorithmique consiste à supprimer l'expansion de certains noeuds. L'idée est de supprimer les noeuds dont le coût est faible et dont le niveau d'expansion dans le graphe est également faible ; par contre, il faut conserver les noeuds dont le coût est faible et qui représentent un maximum de niveaux d'exploration.

Ainsi, si on considère un noeud n_1 de coût c_1 et un noeud n_2 de coût c_2 tels que l'équation (5.9) soit vérifiée alors, c_1 est supprimé.

$$c_1 < c_2 l_2 < l_1 - t \quad \text{et} \quad t = 3 \quad (5.9)$$

- Barret & al [Barret 97] proposent une approche par programmation dynamique pour la détection interactive de contours. L'objectif est de permettre à l'utilisateur d'obtenir, à partir d'un pixel de départ, en chaque pixel de l'image, le contour optimal correspondant. La fonction de coût proposée est une somme pondérée de plusieurs composantes incluant des informations sur le gradient f_G , la direction du gradient f_D , et les passages à 0 du Laplacien f_Z .

Le coût d'un arc est obtenu par l'équation (5.10) :

$$c(P, Q) = \omega_G \cdot f_G(Q) + \omega_Z \cdot f_Z(Q) + \omega_D \cdot f_D(P, Q) \quad (5.10)$$

Les poids sont fixés empiriquement et donnent une importance forte à l'information sur le gradient.

Dans le but de détecter les forts gradients on a (5.11) :

$$f_G = 1 - \frac{G}{\max(G)} \quad (5.11)$$

La valeur f_Z est binaire et vaut 0 si le Laplacien au point considéré est nul, ou si les points voisins ont des signes opposés pour le Laplacien, et 1 sinon.

La composante f_D décrit l'aspect lisse des contours recherchés. Elle a une valeur faible lorsque le pixel Q est dans l'axe du contour déjà construit et forte sinon. Une fonction cosinus est intégrée dans le calcul de cette composante.

Etant donné l'objectif d'interactivité recherché dans cette approche, l'exploration des chemins est systématique dans toute l'image et il n'y a pas d'heuristique pour réduire le nombre de chemins développés. Le principe retenu est de propager les informations de coût selon un "front de propagation" à partir du pixel de départ fourni par l'utilisateur, c'est-à-dire de toujours étendre les noeuds de coût les plus faibles.

Dans la conclusion de cet article, l'auteur mentionne des difficultés pour la détection des structures fines et propose comme perspectives l'intégrations d'outils complémentaires tels que des outils de segmentation en régions. Cette remarque va tout à fait dans le sens de ce que nous proposons pour la fonction de coût de nos agents dynamiques.

- Lecornu & al. [Lecornu 98] ont récemment proposé une approche par programmation dynamique pour la détection de structures vasculaires. L'objectif de ce travail est de permettre une détection automatique des sténoses (rétrécissement anormal d'un vaisseau). L'originalité réside dans la définition de contours parallèles permettant une détection simultanée des 2 contours d'un vaisseau.

La fonction de coût proposée est la somme pondérée de 3 coûts représentant le coût de contraste, le coût d'orthogonalité et le coût de courbure du chemin. Les coefficients de pondération ont été ajustés manuellement. Le coût de contraste est considéré comme l'information la plus importante. L'information *a priori* sur les niveaux de gris permet d'affirmer que les pixels situés à l'intérieur des vaisseaux ont des niveaux de gris plus élevés qu'à l'extérieur. De plus, le suivi simultané des 2 bords d'un vaisseau permet de distinguer entre bord gauche et bord droit.

Le coût de contraste correspond, pour chaque bord, à la différence entre les niveaux de gris situés à l'intérieur et ceux situés à l'extérieur, sur une longueur de 2 pixels correspondant aux 2 noeuds de l'arc en cours d'étude. Ce coût est soustrait à la différence maximale observée dans l'image.

La deuxième composante permet de décrire l'orthogonalité entre les 2 bords et le pseudo-diamètre de la structure. Les pixels réalisant la meilleure orthogonalité ont un coût plus faible.

La troisième composante de la fonction de coût représente le coût de courbure et favorise les pixels qui sont dans l'axe du contour en cours de construction.

Plusieurs heuristiques ont été utilisées pour accélérer le processus de recherche des contours. La première est semblable à celle proposée dans [Martelli 76] pour éliminer les noeuds de coût faible mais correspondant à des niveaux d'exploration également faibles. Une heuristique sur la progression du contour est utilisée pour éliminer les noeuds correspondant à des retours en arrière. De plus, d'autres heuristiques sur la progression des bords et les valeurs de variations des pseudo-diamètres sont utilisées.

- Thedens & al. [Thedens 95] proposent une extension du principe de détection de contours par programmation dynamique au cas d'une séquence d'image de résonance magnétique cardiaque. L'extension consiste à effectuer la recherche d'un graphe optimal dans la séquence vue comme un volume 3D.

La fonction de coût représente le coût d'une surface et correspond à la somme des coûts des arcs inclus dans la surface.

Il est essentiel dans cette application de limiter la complexité de l'algorithme. A nouveau, l'heuristique sur la limitation du nombre de niveaux à étendre est utilisée.

Le travail présenté dans ce document a pour but la mise en oeuvre d'un système de segmentation d'Images de Résonance Magnétique (IRM) cérébrales qui permette de tirer parti de plusieurs approches complémentaires en réponse à la complexité du problème posé. Face à la diversité des approches existant pour la segmentation (classification, modèles déformables,...) nous montrons que l'on peut définir un cadre de travail commun qui permette la mise en oeuvre de coopération entre des approches hétérogènes.

Le cadre méthodologique que nous avons défini s'articule autour des notions d'apprentissage et d'adaptativité. L'apprentissage permet d'introduire des connaissances *a priori*, explicites, sur le contexte de travail sous la forme d'un modèle statistique déformable du contour du cerveau. L'information qui en résulte est exploitée pour spécialiser localement des agents de segmentation, ce qui confère au système son adaptativité.

Nous avons mis en oeuvre trois grands principes de coopération pour réaliser la combinaison d'informations : (i) *coopération par initialisation*, qui exploite le résultat d'une méthode pour initialiser une seconde méthode, (ii) *coopération par fusion d'informations*, qui permet de tirer parti de la fusion de plusieurs sources d'informations complémentaires pour guider une phase de traitement, (iii) *coopération par rétroaction*, qui permet de revenir sur le processus complet de segmentation pour l'affiner ou encore pour transmettre des informations entre images.

L'ensemble du travail a été validé sur des images synthétiques fournies par le Montreal Neurological Institute et illustré sur un ensemble d'images réelles.

Three principles of cooperation for the segmentation of magnetic resonance images of the brain

The goal of our work is the conception and implementation of a segmentation system for Magnetic Resonance Images of the brain. The aim is to combine complementary approaches in response to the complexity of the problem. Given the diversity of the approaches existing for segmentation (classification, deformable models,...) we demonstrate that it is possible to define a common framework to allow cooperation between heterogeneous approaches.

The methodological framework we have defined is based on learning and adaptability. Learning allows for the introduction of *a priori* explicit knowledge about the context under the form of a statistical deformable model of the brain boundary. The resulting information is used to specialise locally agents of segmentation, and thus provides adaptability.

We have designed three principles of cooperation to perform the combination of information : (i) *cooperation through initialisation*, that exploits the result of one method to initialise another method, (ii) *cooperation through fusion of information*, that allows to take advantage of the fusion of complementary sources of information to guide a stage of processing, (iii) *cooperation through retroaction*, that allows to retroact on the whole process of segmentation either to refine it or to transmit information between images.

The whole work has been validated on synthetic data provided by the Montreal Neurological Institute and also illustrated on a set of real images.

