

Thèse présentée pour obtenir le grade de docteur de l'Ecole nationale supérieure des télécommunications

Spécialité: Signal et Images

# Thierry Géraud

## Segmentation des structures internes du cerveau en imagerie par résonance magnétique

Soutenue le 8 juin 1998 devant le jury composé de :

Henri Maître	Président et Directeur de thèse
Marinette Revenu	Rapporteurs
Dirk Vandermeulen	
Christian Roux	Examinateurs
Stéphane Lavallée	
Isabelle Bloch	Co-directeur de thèse

## Ecole nationale supérieure des télécommunications

46, rue Barrault - 75634 Paris Cedex 13 Téléphone 01 45 81 77 77 - Télécopie 01 45 89 79 06 - http://www.enst.fr Groupe des écoles des télécommunications Membre du GEI Paris

# Remerciements

Une thèse n'est pas seulement le reflet du travail d'une personne, elle témoigne aussi d'une période de vie, d'un environnement, d'autres personnes.

C'est le cas en particulier du Professeur Henri Maître, mon directeur de thèse (*grand-chef*), que je remercie pour la confiance qu'il a bien voulu m'accorder, pour son accueil, et pour ses conseils. C'est le cas également du Professeur Isabelle Bloch (*chef*), que je remercie pour son encadrement, son dynamisme, et son influence sur mon travail.

Je tiens sincèrement à remercier les membres du jury pour l'intérêt qu'ils ont porté à mon travail, pour le temps qu'ils m'ont consacré, pour leurs remarques. Tout d'abord, merci au Professeur Marinette Revenu, Responsable du thème Image du GREYC et de la Filière Génie Informatique de l'ISMRA-ENSI à Caen, pour avoir relu mon manuscrit dans le détail, ainsi qu'au Professeur Dirk Vandermeulen, du laboratoire *Medical Image Computing* de l'Université Catholique de Leuven et de l'Hôpital Universitaire de Gasthuisberg. Merci au Professeur Christian Roux, chef du département Image et Traitement de l'Information à l'ENST de Bretagne, pour son soutien à distance, faute d'avions, à Stéphane Lavallée, chargé de recherche CNRS au laboratoire TIMC de l'Institut d'Informatique et de Mathématique Appliquées de Grenoble, pour son inoubliable compliment, et au Docteur Dominique Hasboun de l'Hôpital La Pitié-Salpétrière, pour son enthousiasme scientifique.

Cette thèse s'est déroulée au département Images de l'ENST, où la disponibilité de certains permanents et personnels administratifs n'a d'égale que leurs compétences et leur gentillesse. Je leur exprime toute ma gratitude pour ce qu'ils m'ont apporté. Merci aux Professeurs Alain Maruani et Francis Schmitt pour d'intéressantes discussions, respectivement à propos de modèles physiques et de 3D, et au Docteur Marc Sigelle pour sa relecture très minutieuse du chapitre sur les champs de Markov. Je dois aussi beaucoup à tous ceux qui ont cru en TIVOLI, qui ont participé à sa naissance, qui l'ont aidé à se développer, ou plus modestement, qui l'ont utilisé.

Que serait un département sans son creuset de jeunes doctorants, avec qui j'ai partagé de bons moments. Merci tout particulièrement à la vieille équipe chahuteuse de la C45 (elle seule savait, en l'espace de quelques minutes, transformer cette pièce en véritable central téléphonique ou en plateau de débat télévisé), à Sophie, partenaire de placard, à Nath, JB et Domi, partenaires d'évasion, et à la relève qui ne manque ni d'humour ni de talent.

Je tiens également à exprimer toute ma reconnaissance à ma nouvelle maison d'adoption, qui m'a permis de terminer cette thèse dans d'excellentes conditions et qui m'a soutenu par sa confiance.

Enfin, je souhaite dédier ce travail à mes plus fidèles supporters : mes parents, ma sœur et mon parrain.

# **Table des matières**

Ré	ésumé		1
In	trodı	uction générale	3
I	Ana	atomie cérébrale et son observation en IRM 3D	11
In	trodu	iction	13
1	Ana	tomie relationnelle	15
	1.1	Organisation générale de l'anatomie cérébrale	15
		1.1.1 Terminologie	15
		1.1.2 Les aires du système nerveux central	16
		1.1.3 Les matières du système nerveux central	17
	1.2	Système ventriculaire	17
		1.2.1 Ventricule latéral	18
		1.2.2 Troisième ventricule	18
		1.2.3 Quatrième ventricule	18
	1.3	Substance grise du cerveau	18
		1.3.1 Le cortex	18
		1.3.2 Les noyaux de la base	19
		1.3.3 Les noyaux du diencéphale	21
		1.3.4 La substance grise hors du cerveau	23
	1.4	Substance blanche du cerveau	23
		1.4.1 Les commissures	23
		1.4.2 Les capsules	24
		1.4.3 Le centre semi-ovale	24
	1.5	Autres structures	24
		1.5.1 Les plexi choroïdes	25
		1.5.2 Le claustrum	25
	1.6	Description relationnelle des structures cérébrales	25
		1.6.1 Notion d'objet	25
		1.6.2 Mise en évidence des différents types de relation	27
	. –	1.6.3 Raccourcis d'écriture	30
	1.7	Description des objets par leurs relations	30
	1.8	Conclusion	32

2	L'ob	servatio	on en IRM cérébrale	33
	2.1	Présent	tation des données	33
		2.1.1	Exemple d'une acquisition	33
		2.1.2	Acquisition clinique	37
		2.1.3	A propos du numérique	40
	2.2	Défaut	s des images en IRM 3D	43
		2.2.1	Bruit	43
		2.2.2	Dérive	44
		2.2.3	Mélange et effet de volume partiel	45
		2.2.4	Artefacts	46
	2.3	Modéli	sation radiométrique des classes	48
		2.3.1	Consensus gaussien	48
		2.3.2	Protocole de validation de l'hypothèse gaussienne	48
	2.4	Conclu	ision	51
	2	contra		01
Co	onclus	sion		54
п	Cle	ossificat	tion non contextuelle	57
11	Cla	155111CA	non non contextuene	57
In	trodu	ction		59
•		•••		
3	Clas	sifier et	/ou reconnaître	61
	3.1	Qu'est	-ce que classifier en IRM?	61
		3.1.1		61
		3.1.2	Application à l'IRM 3D	61
	3.2	Qu'est-	-ce que reconnaître en IRM?	62
		3.2.1	Définition	62
		3.2.2	Problématique	62
		3.2.3	Apprentissage	63
		3.2.4	Validation	63
	3.3	Conclu	sion	64
4	Mét	hodes si	inervisées	65
•	4.1	Théorie	e bayésienne de la décision	65
		411	Théorème de Bayes	65
		412	Fonction de décision bayésienne	67
		413	Introduction éventuelle d'un coût	67
	42	Applic	ation bayésienne en IRM 3D	68
	1.2	4 2 1	Problématique	68
		4.2.1	Classe de rejet	68
		4.2.2	Images utilisées	60
	12	T.2.J Mátha	des havésiennes paramétriques	60
	4.3		Estimatour du maximum de vraisemblence	60
		4.3.1	Cos gaussian an dimension 1	90 70
		4.3.2	Cas gaussien en dimension 2 eu plus	70
	1 1	4.3.3	Cas gaussien en unnension 2 ou plus	12
	4.4		Des bayesiennes non parametriques	80
		4.4.1		80

		4.4.2	Fenêtres de Parzen	81
		4.4.3	Conditions de convergence	81
	4.5	Conclu	sion	82
5	Mét	hodes a	utomatiques	83
	5.1	Métho	de des k-moyennes	83
		5.1.1	Nuées dynamiques	83
		5.1.2	Limitations	85
		5.1.3	Mise en pratique des k-moyennes	85
		5.1.4	Exemples d'application en IRM	87
	5.2	Résulta	ats obtenus avec les $k$ -movennes	87
		5.2.1	Choix méthodologiques	87
		5.2.2	Résultats bruts	88
		5.2.3	Influence de la distance	89
		524	Fiabilité de la procédure	91
	53	Algori	thme des <i>c</i> -movennes floues	91
	0.0	5 3 1	Notion de partition floue	94
		532	Adaptation floue des $k$ -movennes	95
		533		97
		534	Critiques	98
	5 /	J.J. <del>4</del>	chiques	101
	5.4	5 / 1	Les transformations histogramme/fonctions d'appartenance	101
		542	Des niveeux de gris eux fonctions d'appartenance	102
		5.4.2	Des inveaux de gris aux fonctions d'appartenance	105
	55	Conclu		105
	5.5	Conciu	151011	107
Co	onclus	sion		110
II	l Se	egment	ation contextuelle	113
In	trodu	ction		115
0	App	roche co	ontextuelle par champs de Markov	117
	0.1	Problem		11/
		0.1.1		118
		6.1.2		118
		6.1.3		119
		6.1.4		120
		6.1.5	Cadre énergétique	120
		6.1.6	Cadre local	121
		6.1.7	Originalité markovienne	122
	6.2	Forme	des fonctions de potentiel	123
		6.2.1	Modèle de Potts	123
		6.2.2	Matrice de Potts	124
		6.2.3	Matrice de Potts 3D	125
		671		105
		0.2.4	Cliques d'ordre I	125

		6.3.1 État de l'art	127
		6.3.2 Comparaison de classifications contextuelles	128
	6.4	Généralisation à des sites et des topologies quelconques	139
		6.4.1 Problématique	139
		6.4.2 État de l'art	142
		6.4.3 Classification de bassins versants	143
		6.4.4 Classification complète	147
	6.5	Conclusion	152
7	Арр	roche contextuelle par morphologie mathématique	155
	7.1	Paramètres	156
	7.2	Segmentation du cerveau	156
		7.2.1 Description de la méthode	156
		7.2.2 Commentaires sur la méthode et sur les résultats obtenus	158
	7.3	Segmentation du liquide céphalo-rachidien	160
		7.3.1 Segmentation simple	160
		7.3.2 Liquide du système ventriculaire	162
		7.3.3 Liquide des sillons	164
		7.3.4 Résultats et discussion	165
	7.4	Segmentation de la substance grise	167
		7.4.1 Segmentation du cortex	167
		7.4.2 Segmentation des noyaux centraux	169
	7.5	Résultat complet et conclusion	169
8	Esti	mation automatique des caractéristiques des tissus purs	175
	8.1	Caractérisation des voxels de mélange en fonction de leur localisation	176
		8.1.1 Localisation des voxels sûrs et purs	176
		8.1.2 Localisation des voxels de mélange	176
	8.2	Carte de plus proche région et interfaces	177
		8.2.1 Procédure d'obtention des interfaces	177
		8.2.2 Application à une classification en IRM	179
	8.3	Estimation des voxels de mélange	180
		8.3.1 Obtention de la radiométrie des tissus purs	180
		8.3.2 Application à la volumétrie d'une pathologie	185
	8.4	Conclusion	187
Co	onclus	sion	190
IV	R	econnaissance progressive par mise en correspondance avec un atlas et fu	-
sic	on flo	ue d'informations structurelles	195
In	trodu	ction	197
9	État	de l'art sur les méthodes de reconnaissance à base d'atlas anatomiques	199
1	9.1	Les atlas existants	199
	<i>,</i> ,,	9.1.1 Du papier au tout numérique	200
		9.1.2 Atlas et normalisation	201

	9.2	Modèle	es de déformation	208
		9.2.1	Primitives points, droites, plans	208
		9.2.2	Primitives linéiques	210
		9.2.3	Primitives surfaciques	211
		9.2.4	Primitives volumiques	214
	9.3	Conclu	sion	215
10	Prés	entation	n générale de la procédure de reconnaissance	217
	10.1	Recont	naissance séquentielle avec informations <i>a priori</i>	217
		10.1.1	Description générale	217
		10.1.2	Description d'une étape	218
	10.2	Justific	ations de nos choix	219
		10.2.1	La séquentialité	219
		10.2.2	L'emploi du flou	220
		10.2.3	Recherche restreinte à une région d'intérêt	221
		10.2.4	Guidage de la segmentation par les informations <i>a priori</i>	221
	10.3	Conclu	sion	222
11				225
11		mps dis	crets de déformations entre atlas et image	225
	11.1	Deform		226
		11.1.1		226
		11.1.2	Vecteurs de correspondance et de deformation	228
		11.1.3	Champ de correspondance	230
		11.1.4	A propos de topologie	232
	11.2	Mise e	n correspondance surfacique	234
		11.2.1	Recalage	235
		11.2.2	Régularisation	237
	11.3	Extens	ion au volume de la mise en correspondance	238
		11.3.1	Champ de laplacien nul	239
		11.3.2	Extension du champ et conditions surfaciques	239
		11.3.3	Algorithme d'extension du champ de correspondance	241
		11.3.4	Modifications de l'algorithme	242
		11.3.5	Initialisation du champ et critère d'arrêt de l'algorithme	244
	11.4	Conclu	sion	246
13	Secon	nontotic	n à nortir de alogoifications contraintes nor fusion d'informations spatiale	a 951
14	12 1	Evores	sion dans l'image de l'objet de référence	8 <b>2</b> 51 251
	12.1	Traduc	tion en images des informations symboliques	251
	12.2	12.2.1	Contrainte speciale	253
		12.2.1		255
		12.2.2		233
		12.2.3	Distance spatiale	258
	10.0	12.2.4		259
	12.3	Obtent	ion d'une region d'interet	261
	12.4	Classif	ications dans la région d'intérêt	263
	12.5	Fusion	des informations et segmentation	267
		12.5.1	Opérateurs de fusion	267
		12.5.2	Similarité entre deux ensembles flous	268
		12.5.3	Informations disponibles	270

		12.5.4 Fusion et sélection	272
		12.5.5 Réalisation de la segmentation	74
	12.6	Conclusion	275
13	Mise	en œuvre de la reconnaissance 2	77
	13.1	Application de la méthode de reconnaissance aux différentes structures 2	277
		13.1.1 Ventricule latéral droit	.79
		13.1.2 Ventricule latéral gauche	83
		13.1.3 Noyau caudé droit	86
		13.1.4 Putamen droit	89
		13.1.5 Quatrième ventricule	90
		13.1.6 Troisième ventricule	93
	13.2	Présentation des résultats	94
	13.3	Commentaire des résultats	10
	13.4	Conclusion	12
Co	noluc	ion 3	11
CU	ncius		14
Co	nclu	sion générale 3	17
Ar	inexe	s 3	23
A	Prise	e en compte de l'anisotropie	
	en tr	aitement d'images 3D 3	825
	A.1	Notations	25
	A.2	Gradients	26
		A.2.1 Cas bidimensionnel	26
		A.2.2 Cas tridimensionnel	27
	A.3	Laplacien	27
	A.4	Diffusion	28
	A.5	Cartes de distances	29
B	Rela	xation markovienne 3	31
	<b>B</b> .1	Schéma général des optimisations markoviennes	31
	B.2	Algorithmes d'optimisation	32
		B.2.1 Échantillonneur de Gibbs	32
		B.2.2 Métropolis	33
		B.2.3 Modes conditionnels itérés	34
		B.2.4 Addition d'un recuit simulé	35
	B.3	Problèmes de mise en œuvre	36
		B.3.1 Balavage des sites	36
		B.3.2 Tirages aléatoires	37

С	Rési	iltats de	e segmentation morphologique	339
	C.1	Le pro	jet GIS	339
		C.1.1	Le cadre du projet	339
		C.1.2	Les images	340
	C.2	Présen	tation des résultats	342
		C.2.1	Résultats de la segmentation du cerveau	342
		C.2.2	Exemples de résultat d'estimation	352
		C.2.3	Résultats de la segmentation du liquide céphalo-rachidien des sillons et des	
			ventricules	354
		C.2.4	Résultats de la segmentation du cortex et des noyaux centraux	361
		C.2.5	Interface gris/blanc	368
		C.2.6	Résultats globaux	375
D	La b	oibliothè	eque TIVOLI de traitements d'images	383
	D.1	Cahier	des charges	383
	D.2 Point de vue critique			
	D.3	Contril	butions	384
	D.4	Exemp	le	384
	Bibl	iograph	ie	387

# Résumé

Pour l'observation neurologique, le caractère *in vivo* des systèmes d'imagerie est attrayant, ce qui explique que les images du cerveau sont maintenant un outil classique de la pratique clinique et de la recherche. Le type d'imagerie par excellence de l'anatomie cérébrale est l'imagerie par résonance magnétique (IRM), et un des principaux enjeux du traiteur d'images est la segmentation automatique des structures cérébrales, sujet de notre travail de thèse. A la clef, le nombre d'applications de la segmentation est important : réalisation de mesures morphométriques, détection de pathologies, planification d'une opération chirurgicale, obtention d'une référence anatomique pour des études fonctionnelles, etc.

L'apport de méthodes de reconnaissance de formes à la classification des différentes matières cérébrales, à partir des seuls niveaux radiométriques des images, comporte certaines limites. Même si elles sont supervisées, ces méthodes ne permettent pas de distinguer facilement différentes classes au sein de la substance grise. Lorsqu'elles sont automatiques, leur utilisation doit s'inscrire dans une procédure empirique afin de garantir un résultat robuste, et doit être restreinte à des régions d'intérêt pour que ce résultat soit véritablement pertinent.

Ces méthodes ne respectant que partiellement la cohérence spatiale des classes dans l'image, nous traitons l'introduction d'informations contextuelles avec des formalismes mathématiques différents. A l'aide d'une régularisation spatiale markovienne tout d'abord, nous montrons que des termes d'énergie de localisation permettent de séparer deux classes de substance grise : le cortex et les noyaux centraux. A l'aide de morphologie mathématique ensuite, nous présentons un ensemble de procédures pour le traitement de divers objets cérébraux ; en particulier, la procédure de segmentation de l'encéphale est robuste et reproductible, et nous obtenons des marqueurs individuels pour les ventricules latéraux, les noyaux caudés, les putamens, et les thalami. Enfin, nous proposons une méthode contextuelle d'estimation des caractéristiques des tissus purs, à partir d'une segmentation grossière.

Notre dernière contribution est de proposer une procédure de reconnaissance progressive, guidée par un atlas. L'originalité de cette procédure est multiple. D'une part, elle prend en compte des informations structurelles sous la forme de contraintes spatiales flexibles, dont le formalisme s'appuie sur la théorie des ensembles flous et de la fusion d'informations. Les méthodes de segmentation présentées précédemment sont alors utilisées non plus globalement, mais conditionnellement à une région d'intérêt de limites imprécises. D'autre part, le calcul de la correspondance entre volume IRM et at-las que nous proposons permet d'inférer un champ de déformation discret, respectant des contraintes sur la surface des objets. Enfin, le caractère séquentiel de la procédure permet de s'appuyer sur la

connaissance des objets déjà segmentés pour accéder à des objets dont l'obtention est *a priori* de plus en plus difficile. Les premiers résultats sont très prometteurs : le ventricule latéral, le noyau caudé, le putamen, et les troisième et quatrième ventricules (à notre connaissance, jamais segmentés automatiquement), sont correctement reconnus. Il reste encore à valider notre procédure sur un jeu d'acquisitions variées.

For neurological studies, the in vivo aspect of imaging systems is very attractive. Brain images are currently a classical tool used in clinical routine and research. The most appropriate system to observe brain anatomy is tridimensional magnetic resonance imaging, and a major issue of image processing is to segment automatically cerebral structures. This is the scope of our thesis. The number of applications is steadily growing: morphometric measurements, pathology detection, surgery planning, getting a reference for functional studies, and so forth.

The use of pattern recognition to classify the different cerebral tissues from the only radiometrical levels of the images is limited. Even supervised, these methods can not lead to distinguish easily several classes of grey matter. When these methods are automatic, their use has to be empirical in order to ensure robust results, and has to be restricted to regions of interest in order to get reliable results.

As these methods do not fully respect the spatial consistency of classes in the images, we have introduced contextual information with the help of different formalisms. With Markovian regularization, we have shown that energical terms of localization permit the separation of two grey classes: cortex and central nuclei. With mathematical morphology, we have proposed processing chains dedicated to several cerebral objects; in particular, brain segmentation is robust and reproducible, and we have successfully obtained individual markers for lateral ventricles, caudate nuclei, putamen and thalami. We have also proposed a contextual method to estimate pure tissue characteristics from a rough segmentation.

Our main contribution has been to present a recognition method which is progressive and atlas guided. The originality of this method is manifold. At first, it takes into account structural information processed as flexible spatial constraints the formalism of which relies on fuzzy set theory and information fusion theory. Segmentation approaches that have been presented are not used globally any more but conditionally to regions of interest with imprecise limits. Furthermore, we propose a new way of computing the correspondance between the MRI volume to be processed and the atlas; this calculation infers a discrete deformation field constrained by object surfaces. At last, the method sequentiality allows us to rely on objects that have been already recognized to perform the segmentation of objects which is a priori more and more difficult. Our first results are very promising: lateral ventricles, caudate nuclei, putamen and the third and fourth ventricles (that have never been automatically segmented until now) are correctly recognized. Our method still needs to be validated on a large set of various images. Introduction générale

La compréhension du cerveau humain et de son fonctionnement constitue une véritable gageure, comme l'illustre par exemple la traduction en français sous le titre « *Le cerveau : un inconnu* » [COLL-93] du traité de neurologie « *The Oxford companion to the mind* » [COLL-87].

Pour l'étude du cerveau, le caractère *in vivo* des systèmes d'imagerie cérébrale est attrayant. Avec la qualité sans cesse croissante de l'instrumentation, des méthodes de reconstruction, et des séquences d'acquisitions, les images du cerveau sont devenues un outil maintenant classique de la pratique clinique. La vision du cerveau est multiple: les structures anatomiques, les vaisseaux sanguins, et plus récemment, les zones d'activation fonctionnelle, sont aujourd'hui accessibles.

Pour l'anatomie cérébrale, le type d'imagerie par excellence est l'imagerie par résonance magnétique (IRM), et un des principaux enjeux du traiteur d'images est la segmentation automatiques des structures cérébrales. A la clef, le nombre d'applications de la segmentation est lui aussi croissant.

- En premier lieu, l'étude de certaines structures sur un nombre important de sujets sains et pathologiques permet de définir l'influence de pathologies sur la morphologie et la morphométrie de ces structures. A terme, l'intérêt principal ne sera pas de diagnostiquer ces pathologies, connues par ailleurs, mais de les dépister chez des sujets sensibles.
- Lorsque le patient présente une pathologie, la segmentation des structures internes peut renseigner le praticien sur les dommages occasionnés. L'estimation du volume pathologique, effectué lors du suivi de l'évolution d'une pathologie au cours d'un traitement, pourrait être alors détaillée pour chaque structure touchée.
- La segmentation de l'anatomie du cerveau est également une aide à la chirurgie et à la radiothérapie. En phase de planning, l'accès à une pathologie profonde qui minimise les risques d'endommagement des structures cérébrales pourra être déterminé automatiquement. En phase opératoire, lorsque l'assistance en direct par imagerie sera une réalité, la visualisation du cerveau pourra être augmentée par l'identification des structures [GRIM-97].
- La segmentation est indispensable au calcul d'un maillage des régions cérébrales, nécessaire à de nombreuses études.
  - En magnéto-encéphalographie (MEG) ou en électro-encéphalographie (EEG), un tel maillage, individuel à chaque patient, permet de modéliser le milieu conducteur complexe que représente le cerveau avec ses différents tissus [HAMA-89]; ainsi le problème inverse de reconstruction du champ magnétique ou du potentiel dans le volume cérébral peut être possible [BAIL-97], et la localisation des sources de courant, à l'origine des signaux enregistré sur le scalp, peut être mieux identifiée.
  - En tomographie par émission de positrons (TEP), les images de transmission peuvent être simulées, au lieu d'être acquises en début d'examen ; cela évite donc une irradiation supplémentaire du sujet [LEGO-94].

#### 6 Introduction générale

- Enfin, citons une étude qui devient très à la mode : la simulation de la propagation dans les tissus biologiques des micro-ondes électromagnétiques dues aux téléphones cellulaires ; il s'agit alors d'évaluer les effets thermiques et non thermiques (fonctionnels, risques de développer des pathologies), entraînés par un temps de cuisson quotidien.
- Pour des études fonctionnelles menées sur un sujet, en imagerie par résonance magnétique fonctionnelle (IRMf) ou en TEP, l'acquisition supplémentaire d'une image anatomique de ce sujet, suivie de sa segmentation, offre une référence anatomique. Les zones d'activation sont alors localisées avec précision dans les régions anatomiques du sujet.

Le but de cette thèse est la segmentation des structures cérébrales internes en imagerie par résonance magnétique tridimensionnelle. La segmentation, technique récurrente en traitement des images (Cf. les revues [KANA-80, FU-81, HARA-85b, PAL-93]), intervient naturellement en imagerie médicale [SUET-93]. Plus particulièrement, la segmentation a donné lieu, dans le cadre de son application aux structures cérébrales, à une abondante recherche, comme en témoignent les revues [BEZD-93, LIAN-93, CLAR-95].

Les principales méthodes utilisées dans la littérature sont rappelées ici rapidement.

- Par détection de surface [FU-81]: dans [EHRI-90], l'opérateur de Marr-Hildreth [MARR-80] est utilisé; dans [BOMA-90] et [SAND-94c], il est combiné avec de la morphologie mathématique; dans [RAMA-91], l'opérateur est le laplacien de l'image filtrée par une gaussienne; dans [ASHT-90] et dans [WAKS-90], un suivi de contour est destiné à la segmentation du cerveau.
- Par croissance de région [ZUCK-76]: dans [CLIN-87] et dans [GARZ-96], la croissance a également pour but de segmenter le cerveau; dans [ORTE-85], la croissance est hiérarchique; dans [XUAN-95], la croissance est consécutive à une détection de contours par filtrage de Canny [CANN-86a], suivie d'un lissage qui préserve les contours.
- Par seuillage [GLAS-93]: dans [LIM-89, KUND-90, SUZU-91, BRUM-92, JOLI-93], les structures cibles sont variées (le fond, le liquide céphalo-rachidien, la substance grise, la substance blanche, le crâne, ou le cerveau), et le seuillage est généralement suivi de post-traitements; dans [BRUM-92] et [JOLI-93] par exemple, il s'agit d'opérateurs de morphologie mathématique; dans [DIGE-94], la surface se déduit du seuillage par un opérateur local de type Sobel; dans [VEHK-95], un seuillage par hystérésis est le début d'une procédure semi-automatique.
- Par classification non contextuelle [DUDA-73]: les résultats, quelle que soit la méthode employée, ne discriment que le fond, le liquide céphalo-rachidien, la substance grise, la substance blanche, et une éventuelle pathologie.
  - Avec des réseaux de neurones, l'apprentissage est supervisé [DAWA-91, HALL-92, ZIJD-93, OZKA-93], ou non supervisé [AMAR-92, CLAR-93, PAL-93b, RAFF-94, CHEN-96, REDD-97].
  - Avec des méthodes bayésiennes paramétriques, l'apprentissage est supervisé, et généralement deux modalités d'acquisitions IRM sont utilisées [CLIN-91, VANN-91, KOHN-91, AGAR-92, COHE-92b, CLAR-93, FLET-93, TAXT-94, BLAT-95, KAMB-95, MCCL-95].

- Parmi les méthodes automatiques, citons l'algorithme des k-plus proches voisins [KIKI-92, CLAR-93, JACK-93, MITC-94], celui des k-moyennes [VANN-88, GERI-92b, VELT-95], et celui des c-moyennes floues [HALL-92, LI-93, SHIM-93, BENS-94b, BRAN-94, CLAR-94, PHIL-95, PHAM-97]. Dans [DIGE-94], les résultats de quatre classifieurs différents sont combinés, globalement ou séquentiellement, pour améliorer la décision finale.
- Par classification markovienne [GEMA-87]: sans estimation des hyper-paramètres [SANT-93, VAND-93, FESS-94, LUND-95, YAN-95, AURD-97, CHOI-97, HELD-97, JAGG-97], ou avec estimation des hyper-paramètres [LIAN-94, WANG-94a, LI-95, MARD-96], les classes considérées sont les mêmes que celles des classifications non contextuelles.
- Par morphologie mathématique [SCHM-94] : peu nombreuses [SAND-94c, CONN-91, ALLA-93, JOLI-93, MANG-95a, TSAI-95], les méthodes s'intéressent essentiellement à la segmentation du cerveau, et aux séparations entre sillons et cortex, et entre cortex et substance blanche ; dans [HOHN-92b], la segmentation de différentes structures est proposée, mais de façon interactive.
- Par contour déformable [KASS-88]: les structures cérébrales traitées sont l'hippocampe, reconstruit à partir d'une suite de contours [ASHT-95, GHAN-96], certains tissus mous [CARL-95], le contour de la tête [EVIA-96], et en 2D<sup>1</sup>/<sub>2</sub>, l'encéphale, ses deux hémisphères, et le cervelet [FADI-97]. Une extension des méthodes de contours déformables à la troisième dimension a déjà donné des résultats.
  - Par un modèle élastique : la surface cérébrale, après lissage de l'image pour faciliter la convergence [SAND-94a], l'interface entre substance grise et substance blanche, et de façon approximative le système ventriculaire [TEK-95].
  - Dans [MANG-95a], après une initialisation de la segmentation de la surface externe du cortex par des pré-traitements morphologiques, cette surface est obtenue avec précision par un modèle dont les déformations sont contraintes de façon homothopique.
  - Par un modèle discret masses-ressorts : les ventricules cérébraux [FLAS-97].
  - Par déformation d'une surface de Fourier : le thalamus et le noyau caudé [STAI-97], et les ventricules latéraux [UNDR-97].
- Par un système à base de connaissances dans [DELL-92]: une étape d'apprentissage fournit des descriptions discriminantes des objets cérébraux et de leurs relations, puis la reconnaissance est effectuée à l'aide de mesures de similarité entre des régions de l'image, obtenues par sur-segmentation, et des connaissances exprimées par des ensembles flous.
- Par déformation d'atlas : une revue détaillée est donnée au chapitre 9.

La segmentation par certaines approches semble donc, de par leur caractère trop général, limitée aux matières cérébrales principales (liquide céphalo-rachidien, substance grise, et substance blanche) et aux interfaces correspondantes; en revanche, l'obtention d'une structure interne particulière est possible, mais nécessite de mettre en œuvre une approche dédiée à cette structure.

L'objectif de cette thèse est de segmenter les structures internes du cerveau en proposant une méthode générale, plutôt que des algorithmes spécifiques pour chaque structure. Nous essayons tout d'abord d'extraire le plus d'informations possible des images elles-mêmes, sans introduction de modèle. Puis nous combinons ces informations avec un modèle, constitué d'un atlas et de connaissances *a priori*, pour proposer une méthode générale de reconnaissance. Ce manuscrit est composé de quatre parties.

La première partie est dédiée à l'anatomie cérébrale et à son observation en imagerie par résonance magnétique tridimensionnelle. En particulier, nous insistons sur les diverses relations spatiales qui existent entre les structures cérébrales.

La deuxième partie concerne l'apport de certaines méthodes de classification non contextuelle pour notre problématique. Cette partie présente les résultats que ces méthodes permettent d'obtenir, les informations que nous pouvons en tirer pour des traitements ultérieurs, ainsi que leurs limites.

La troisième partie s'intéresse à l'introduction d'informations contextuelles avec des formalismes différents : sous forme de régularisation spatiale markovienne, puis sous forme morphologique. Ensuite, une étude des interfaces entre structures montre comment des estimations radiométriques précises peuvent être obtenues pour les structures.

Enfin, la quatrième et dernière partie propose une procédure originale de reconnaissance des structures cérébrales internes. La reconnaissance est progressive, guidée par une mise en correspondance avec un atlas, et par la fusion floue d'informations structurelles.

•

Première partie

# Anatomie cérébrale et son observation en IRM 3D

# Introduction

L'anatomie cérébrale en imagerie par résonance magnétique est simple et complexe à la fois.

Simple parce que les structures les mieux contrastées et les plus volumineuses s'identifient facilement : leur organisation, leur localisation et leur forme permettent de les reconnaître rapidement avec un minimum d'entraînement et leur nombre ne dépasse pas une vingtaine.

Complexe parce que, dès que le plan de coupe change, ce début d'expertise que nous croyons avoir acquis disparaît; nous ne retrouvons plus les repères visuels que nous attendions et sur lesquels reposait en fait notre maigre savoir. En observant presque exclusivement un volume IRM en vue axiale par exemple, ou sinon avec quelques vues sagittales et coronales, et généralement toujours les mêmes, notre compréhension réelle de la morphologie cérébrale est donc très réduite. La complexité provient également de la complexité intrinsèque du cerveau, indépendamment de l'acquisition en IRM.

Avec l'avènement des technologies liées à la visualisation tridimensionnelle, le traiteur d'images peut afin appréhender l'anatomie cérébrale de façon spatiale comme le fait naturellement le neuroclinicien.

La première partie de ce manuscrit est dédiée à l'anatomie cérébrale (chapitre 1) et à son observation en imagerie par résonance magnétique (chapitre 2).

Les structures cérébrales, que nous allons segmenter par la suite, sont décrites rapidement mais à l'aide de métaphores morphologiques et illustrées par des visualisations 3D<sup>1</sup>. Une description des relations entre structures fait l'objet de la fin du premier chapitre ; ces relations seront utilisées principalement dans la partie IV.

Nous introduisons ensuite les caractéristiques de l'observation des structures cérébrales dans les images par résonance magnétique. Les conclusions que nous tirons de l'étude de ces caractéristiques vont conditionner les traitements numériques que nous mettrons en œuvre dans les parties II, III et IV.

<sup>1.</sup> ces visualisations sont des images retravaillées tirées du site Internet du projet américain *Digital Anatomist Program* décrit en section 9.1.1

## **Chapitre 1**

# **Anatomie relationnelle**

Ce chapitre n'a ni la prétention d'être un traité d'anatomie cérébrale ni celle *a fortiori* d'être exhaustif. Il présente succinctement un certain nombre de structures cérébrales anatomiques <sup>1</sup> observables en IRM 3D sous le jour des relations qui existent entre elles.

Pour élaborer ce chapitre, nous avions à notre disposition plusieurs livre-atlas du cerveau humain ; nous en avons retenu un [NIEU-88], particulièrement clair et complet. Avec l'essor d'*Internet*, on trouve sur le réseau mondial de nombreuses pages sur l'anatomie cérébrale ; citons pour l'exemple le collège de médecine de l'université de l'Iowa U.S.A. qui met à notre disposition un cours détaillé et illustré d'anatomie cérébrale : *The Virtual Hospital*<sup>2</sup>.

Après une présentation générale (section 1.1), nous décrivons successivement les structures que nous envisageons de segmenter : système ventriculaire (section 1.2), substance grise (section 1.3), substance blanche (section 1.4), et quelques autres structures plus petites (section 1.5).

Comme la reconnaissance des structures s'appuie non seulement sur les caractéristiques propres de chacune d'elles mais aussi sur les relations entre elles, nous présentons dans les sections 1.6 et 1.7 les relations entre structures, que nous utiliserons dans la partie III pour les plus simples, et surtout dans la partie IV.

## 1.1 Organisation générale de l'anatomie cérébrale

Avant de parler de la structure interne du cerveau, commençons par rappeler quelques termes couramment utilisés en anatomie cérébrale.

#### 1.1.1 Terminologie

Les termes décrivant l'orientation dans le cerveau sont :

- inférieur, vers le bas du cerveau (en direction du cou),
- supérieur, inverse d'inférieur,

<sup>1.</sup> A chaque structure nous avons attribué un identificateur donné dans le texte en note de bas de page.

<sup>2.</sup> http://www.vh.org/Providers/Textbooks/BrainAnatomy/BrainAnatomy.html

- antérieur, vers l'avant du cerveau (en direction du visage),
- postérieur, inverse d'antérieur,
- médial, vers le plan de symétrie du cerveau,
- *latéral*, inverse de médial (en direction de chaque oreille).

Un objet cérébral est dit *médian* lorsqu'il occupe le plan interhémisphérique, plan de symétrie du cerveau. Il ne présente alors qu'une composante connexe, symétrique par rapport à ce plan. Par opposition, un objet non-médian est constitué de deux parties non-connexes; chaque partie (gauche ou droite) est symétrique de l'autre et occupe un des deux hémisphères cérébraux (respectivement, gauche ou droit).

Des coupes *axiale*, *coronale* et *sagittale* sont des coupes du cerveau approximativement parallèles, respectivement, au plan qui comprend nez et oreilles, au plan du visage et au plan de symétrie de la tête. Ces coupes sont orthogonales deux à deux.

#### 1.1.2 Les aires du système nerveux central

Le système nerveux central se compose de trois parties : la *moelle épinière*<sup>1</sup> (partie caudale), le *tronc cérébral*<sup>2</sup> (partie moyenne) et le *cerveau* appelé encore *prosencéphale*<sup>3</sup> (partie supérieure). L'*encéphale*<sup>4</sup> est formé du tronc cérébral et du cerveau.

#### La moelle épinière

Très allongée, elle est logée dans le *canal rachidien*. Au centre de la moelle épinière coule le *canal central*<sup>5</sup>.

#### Le tronc cérébral

Le tronc cérébral, logé dans la fosse postérieure du crâne, se compose de trois parties superposées auxquelles est appendue une quatrième partie, le *cervelet*<sup>6</sup>.

- La moelle allongée<sup>7</sup> (ou myélencéphale), partie inférieure, a une forme de cône tronqué à petite base inférieure qui fait suite à la moelle épinière.
- L'isthme<sup>8</sup> (ou mésencéphale), partie supérieure, réunit deux cylindres aplatis et divergents.
- Le *pont*<sup>9</sup>, partie moyenne, fait une saillie sous laquelle paraît s'engager la moelle allongée et d'où paraît sortir l'isthme.

- 3. *A\_PRO* pour prosencéphale.
- 4.  $A\_ENC$  pour encéphale.
- CAN pour canal central.
  A\_CVL pour cervelet.

<sup>1.</sup>  $A\_MOE$  pour moelle épinière.

<sup>2.</sup> *A\_TRC* pour tronc cérébral.

A = 0 V E pour cerveret.

A\_MOA pour moelle allongée.
 A\_ISM pour isthme.

o A DMT

<sup>9.</sup>  $A\_PNT$  pour pont cérébral.

 Le cervelet, volumineuse masse médiane, est relié à chacune des parties précédentes par des pédoncules. Il se divise en deux hémisphères avec au centre, le *vermis*<sup>1</sup>.

La réunion du pont et du cervelet est appelée *métencéphale*<sup>2</sup>; celle du métencéphale et de la moelle allongée, *rhombencéphale*<sup>3</sup>.

#### Le cerveau

Masse ovoïde située dans la loge supérieure du crâne, le cerveau est composé du *télencéphale*<sup>4</sup> et du *diencéphale*<sup>5</sup> (ou cerveau intermédiaire). On distingue dans le télencéphale deux hémisphères symétriques, droit et gauche, séparés par la *scissure interhémisphérique*<sup>6</sup>, fissure transverse (ou fente de Bichat). Ces hémisphères sont unis sur leur face médiale par le diencéphale et par les commissures interhémisphériques. Ils entourent par leur base l'isthme et la partie inférieure du diencéphale.

Si, embryologiquement et morphologiquement, on partage le cerveau en télencéphale et diencéphale, sur le plan fonctionnel, la distinction est tout autre. On définit deux nouvelles aires : le *paléencéphale*<sup>7</sup> (système sous-cortical), comprenant principalement le diencéphale et les noyaux de la base, et le *néencéphale*<sup>8</sup> (système cortical), comprenant le cortex et une grande part de la substance blanche télencéphalique.

#### 1.1.3 Les matières du système nerveux central

Le système nerveux central est d'un point de vue quantitatif constitué de trois matières principales que l'on retrouve dans chacune de ses aires.

Il y a deux substances de coloration différente : la *substance grise*<sup>9</sup>, constituée de cellules nerveuses et de synapses ainsi que de tissus de soutien, et la *substance blanche*<sup>10</sup>, constituée par des fibres myéliniques groupées en faisceaux. La troisième matière principale est un liquide, le *liquide céphalo-rachidien*<sup>11</sup>.

Hormis ces trois matières, notons l'existence de tissus servant de parois, de veines cérébrales, et de nombreuses autres structures de petite taille (des glandes par exemple).

## 1.2 Système ventriculaire

Le liquide céphalo-rachidien baigne la surface extérieure du cerveau et du cervelet et remplit le système ventriculaire. Ce système, représenté en figure 1.1, comporte quatre cavités qui communiquent entre elles : les deux *ventricules latéraux*<sup>12</sup> du télencéphale, le *troisième ventricule*<sup>13</sup> (médian) du diencéphale et le *quatrième ventricule*<sup>14</sup> (médian) du métencéphale.

<sup>1.</sup>  $A\_VER$  pour vermis.

<sup>2.</sup>  $A\_MET$  pour métencéphale.

<sup>3.</sup> A\_RHO pour rhombencéphale.

<sup>4.</sup>  $A\_TEL$  pour télencéphale.

<sup>5.</sup>  $A\_DIE$  pour diencéphale.

<sup>6.</sup> SCI pour scissure interhémisphérique.

<sup>7.</sup>  $A\_PAL$  pour paléencéphale.

<sup>8.</sup>  $A\_NEE$  pour néencéphale.

<sup>9.</sup>  $M\_SGR$  pour substance grise.

<sup>10.</sup>  $M\_SBL$  pour substance blanche.

<sup>11.</sup>  $M\_LCR$  pour liquide céphalo-rachidien.

<sup>12.</sup> VTL pour ventricule latéral.

<sup>13.</sup> VT3 pour ventricule III.

<sup>14.</sup> VT4 pour ventricule IV.

#### **1.2.1** Ventricule latéral

Cavité de l'hémisphère, le ventricule latéral forme un anneau ouvert. Son extrémité antérosupérieure est dite *corne antérieure* (ou frontale); plus minces, les extrémités antéro-inférieure et postéro-inférieure sont appelées respectivement *corne inférieure* (ou temporale) et *corne postérieure*. La partie la plus volumineuse du ventricule latéral, qui surplombe le thalamus, forme le corps et la jonction du corps et des cornes inférieure et postérieure se nomme *atrium* (ou carrefour).

#### 1.2.2 Troisième ventricule

Cavité médiane du diencéphale, il communique avec chaque ventricule latéral par un orifice, le *trou de Monro*<sup>1</sup> (ou foramen interventriculaire), et avec le quatrième ventricule par l'*aqueduc de Sylvius*<sup>2</sup> (ou aqueduc du mésencéphale). Les parois latérales sont presque en contact l'une de l'autre. L'étage supérieur (ou thalamique) est marqué par l'*adhérence interthalamique*<sup>3</sup> (ou commissure grise), pont de substance grise.

#### 1.2.3 Quatrième ventricule

Cavité du tronc cérébral, le quatrième ventricule est une boîte en forme de losange, qui répond à la partie dorsale de la moelle allongée et du pont, et qui semble pénétrer le cervelet. Elle se continue supérieurement par l'acqueduc de Sylvius pour se jeter dans le troisième ventricule, et inférieurement par le canal central de la moelle.

#### **1.3** Substance grise du cerveau

La substance grise du proencéphale se compose du *cortex*<sup>4</sup> télencéphalique et des *noyaux centraux*<sup>5</sup>.

#### 1.3.1 Le cortex

Constituant la surface grise du télencéphale, le cortex, ou écorce cérébrale, est caractérisé par de nombreuses dépressions appelées sillons. Les plus profonds, sillons primaires, définissent les lobes cérébraux (frontal, pariétal, temporal et occipital). Les moins profonds, sillons secondaires, délimitent les circonvolutions ou gyri. La surface externe du cortex représente environ 22 000 cm<sup>2</sup> dont deux-tiers sont enfouis dans les sillons.

Le cortex est formé de cellules, dont le nombre est estimé à plus de dix milliards, disposées en couches superposées. Son épaisseur moyenne au sommet d'une circonvolution est de 2,6 mm, son épaisseur maximale pouvant atteindre plus de 4,5 mm. Sous l'enveloppe corticale, se trouve la matière blanche.

Lorsque les deux parties du cortex semblent se toucher, elles sont en fait séparées par la scissure interhémisphérique. L'extérieur du cortex baigne, tout comme l'intégralité du volume encéphalique, dans le liquide céphalo-rachidien.

<sup>1.</sup> MON pour trou de Monro.

<sup>2.</sup> SYL pour aqueduc de Sylvius.

<sup>3.</sup> ADH pour adhérence interthalamique.

<sup>4.</sup> CTX pour cortex.

<sup>5.</sup> NCE pour noyaux centraux



FIG. 1.1 – Système ventriculaire

Cette figure représente le système ventriculaire en vue antéro-latérale (en haut) et en vue inférieure (en bas) ; sont indiqués pour le ventricule latéral : la corne antérieure (1), le corps (2), l'atrium (3), la corne inférieure (4), la corne postérieure (5) ; les autres structures du système ventriculaire sont : le troisième ventricule (6) ; le quatrième ventricule (7) ; le trou de Monro (8) ; l'aqueduc de Sylvius (9) ; la moelle épiniaire (10).

La figure 1.2 est une vue tridimensionnelle de l'encéphale avec une extrusion de la moitié antérieure de l'hémisphère gauche. La surface externe du cortex sous-crânien y est visible à droite, en haut et à gauche, et la surface externe du cortex proche de la scissure inter-hémisphérique, à gauche du centre de la figure. Les circonvolutions apparaissent sur la demi-section coronale.

#### 1.3.2 Les noyaux de la base

Les *noyaux centraux*, qui sont avec le cortex les seules structures de substance grise du cerveau, sont composés des noyaux du télencéphale et des noyaux du diencéphale. Ces premiers sont appelés *noyaux de la base*<sup>1</sup> (ou corps strié). Parmi eux, on distingue les *noyaux caudés*<sup>2</sup> et les *noyaux lenticulaires*<sup>3</sup>. Tous sont non-médians.

#### Noyaux caudés

En forme de virgule à grosse extrémité, le noyau caudé est presque complètement enroulé autour du thalamus. Il longe à peu près dans toute son étendue le ventricule latéral (voir plus loin sa description en section 1.2.1). On lui distingue trois parties : la tête, située en avant, renflée en massue et pratiquement verticale, le corps, plus mince et logé contre la paroi latérale du ventricule latéral, et la queue, qui devient horizontale, forme le toit de la corne inférieure du ventricule latéral puis s'effile progressivement.

<sup>1.</sup> *NBA* pour noyaux de la base.

<sup>2.</sup> NCA pour noyau caudé.

<sup>3.</sup> *NLE* pour noyaux lenticulaires.



FIG. 1.2 – Vue extrudée de l'encéphale

Cette figure montre une partie de la surface du cortex avec ses sillons et un certain nombre de structures que nous détaillerons par la suite : le corps calleux (1), le noyau caudé (2), le putamen (3), le pallidum (4), le ventricule latéral (5), le thalamus (6), la commissure antérieure (7), la capsule extrême (8), le claustrum (9), la capsule externe (10) et la capsule interne (11).

La figure 1.3 est dédiée au noyau caudé ; ce dernier apparaît aussi en section dans les figures 1.2, 1.4 et 1.5.

#### **Noyaux lenticulaires**

Le noyau lenticulaire se situe en dehors du noyau caudé et du thalamus. Sa forme est celle d'une lentille biconvexe, triangulaire sur les coupes axiales et coronales. Sa face médiale fait un angle dièdre répondant à celui formé par les faces latérales de la tête du noyau caudé et du pôle antérieur du thalamus.

Le noyau lenticulaire se compose du *putamen*<sup>1</sup> (externe) et du *pallidum*<sup>2</sup> (interne). La distinction entre ces deux structures est visible en figure 1.2. L'extrémité antérieure du putamen est soudée par sa base inférieure au noyau caudé par un pont de substance grise (ou aire accumbens), représenté en figure 1.4. Le pallidum (ou globus pallidus), figure 1.5, est formé de deux parties, une médiale et une latérale.

<sup>1.</sup> PUT pour putamen.

<sup>2.</sup> PAL pour pallidum



FIG. 1.3 – Noyau caudé

Le noyau caudé, dont le contour a été noirci, se love sur le ventricule latéral ; sur cette figure, la tête du noyau caudé est à gauche, son corps est en haut et sa queue en bas à droite.



FIG. 1.4 – Aire accumbens

L'aire accumbens (gauche et droite) est représentée en 3D avec un contour noir, en avant d'une section coronale de l'encéphale; sur cette section sont visibles: la corne antérieure des ventricules latéraux (en très foncé), la tête des noyaux caudés (en clair) qui s'appuie sur la paroi latérale des ventricules, et les noyaux lenticulaires reliés aux noyaux caudés par l'aire accumbens.

### 1.3.3 Les noyaux du diencéphale

Formant les noyaux centraux avec les noyaux du télencéphale, les noyaux du diencéphale sont le *thalamus*<sup>1</sup> et l'*hypothalamus*<sup>2</sup>.

#### Thalamus

Illustré en figure 1.6, c'est le plus volumineux des noyaux gris centraux. Avec ses 3 cm de long, il possède une grosse extrémité postérieure et un grand axe oblique en avant qui rentre légèrement

<sup>1.</sup> THA pour thalamus.

<sup>2.</sup> HYP pour hypothalamus.



FIG. 1.5 – Pallidum

En contour noir, le pallidum est représenté sortant d'une section coronale de l'encéphale (section postérieure à celle de la figure 1.4); sur cette section sont visibles : le corps des ventricules latéraux (en très foncé) et des noyaux caudés (en clair), sous ces premiers le thalamus en forme de cœur (en foncé), et à droite sur cette figure entre le pallidum et le cortex, le putamen puis le claustrum (en clair).

vers l'intérieur. Non-médians, les thalami gauche et droit sont séparés par la cavité du troisième ventricule mais se touchent par l'adhérence interthalamique. Enfin, leur face inférieure répond à l'hypothalamus.



FIG. 1.6 - Thalamus

En coutour noir, le thalamus s'inscrit dans l'anneau ouvert que forme le ventricule latéral.

#### Hypothalamus

De petites dimensions, il a la forme d'un entonnoir appendu sous le thalamus et constitue la partie inférieure des parois latérales du troisième ventricule.



FIG. 1.7 – Hypothalamus

L'hypothalamus, de teinte claire et de contour noir sur cette figure, masque partiellement le troisième ventricule.

#### 1.3.4 La substance grise hors du cerveau

Toute aire du système nerveux central comporte de la substance grise. Une coupe de la moelle épinière révèle la substance grise centrale en forme de X. Dans le tronc, elle est constituée par les noyaux des nerfs crâniens et les noyaux propres au tronc cérébral ; les premiers prolongent, suivant six colonnes de rôles fonctionnels différents, la substance grise de la moelle épinière, tandis que les seconds sont épars. Le cervelet, organe terminal au même titre que le télencéphale, possède comme lui une écorce grise superficielle.

## **1.4** Substance blanche du cerveau

Située sous le cortex, baignant les noyaux, la substance blanche se situe entièrement dans le télencéphale. Elle comprend des *commissures interhémisphériques*<sup>1</sup> (le *corps calleux*<sup>2</sup> et la *commissure antérieure*<sup>3</sup>), des *capsules*<sup>4</sup> et le *centre semi-ovale*<sup>5</sup>.

#### 1.4.1 Les commissures

#### Le corps calleux

C'est une épaisse lame enroulée avec le télencéphale autour du diencéphale. Elle s'incurve en arrière formant le *splenium* au-dessus du mésencéphale (et de sa *lame quadrijumelle*). En avant, en bas du pôle antérieur du diencéphale, elle forme le *genou* puis le *rostrum* (bec), qui se termine sur la paroi antérieure du troisième ventricule et s'appuie sur la commissure antérieure.

#### La commissure antérieure

C'est un petit cordon blanc horizontal, qui s'étend d'un pôle temporal à l'autre, en passant en avant de la paroi antérieure du troisième ventricule, entre la lame terminale en avant et les colonnes

<sup>1.</sup> CMI pour commissure interhémisphérique.

<sup>2.</sup> CAL pour corps calleux.

<sup>3.</sup> *CMA* pour commissure antérieure.

<sup>4.</sup> *CAP* pour capsule.

<sup>5.</sup> CSO pour centre semi-ovale.

du fornix en arrière.



FIG. 1.8 – Commissure antérieure

En contour noir, la commissure antérieure traverse la scissure inter-hémisphérique; cette figure comporte aussi les deux ventricules latéraux, les thalami et hypothalami, des éléments du tronc cérébral, et derrière eux, une moitié de cervelet.

#### Le fornix

Le *fornix*<sup>1</sup> est une mince commissure interhémisphérique composée d'un corps et de quatre piliers (ou colonnes).

#### 1.4.2 Les capsules

Les capsules sont de fines surfaces de substance blanche. On distingue la *capsule interne*<sup>2</sup>, la *capsule externe*<sup>3</sup> et la *capsule extrême*<sup>4</sup>. La première se situe entre le diencéphale et les noyaux lenticulaires, la seconde entre les noyaux lenticulaires et le *claustrum*, et la dernière entre le claustrum et le cortex.

La capsule interne répond au noyau caudé par son bras antérieur et au thalamus par son bras postérieur; elle forme donc une sorte de V, articulé autour de son genou.

#### 1.4.3 Le centre semi-ovale

La substance blanche, située dans les deux hémisphères, entre cortex et noyaux, a dans son ensemble une forme semi-ovale, d'où son nom de centre semi-ovale.

## **1.5** Autres structures

Présentons maintenant un certain nombre de structures, moins volumineuses que les précédentes, mais que nous retrouverons par la suite.

<sup>1.</sup> FNX pour fornix.

<sup>2.</sup> *CAI* pour capsule interne.

<sup>3.</sup> CAE pour capsule externe.

<sup>4.</sup> CAM pour capsule extrème

#### 1.5.1 Les plexi choroïdes

Les deux plexi choroïdes, cordons vasculaires extraventriculaires proviennent de la scissure interhémisphérique, parcourent le plancher du corps ventriculaire, la paroi antéro-médiale de l'atrium puis le toit de la corne inférieure.

Ce sont eux qui sécrètent le liquide céphalo-rachidien.

#### 1.5.2 Le claustrum

Structure fine et verticale, le claustrum (figure 1.9) se loge dans chaque hémisphère entre le cortex et les noyaux de la base.



FIG. 1.9 - Claustrum

En contour noir, le claustrum est représenté en 3D, en avant d'une section coronale du volume encéphalique. Les structures observables sur cette section sont listées dans la légende de la figure 1.5 ; notons qu'ici, le putamen et le pallidum sont bien distingués (juste à droite du claustrum de gauche).

## 1.6 Description relationnelle des structures cérébrales

Le but de cette section est de décrire l'ensemble des objets évoqués précédemment, à l'aide de différents types de relations que nous mettons en évidence.

#### 1.6.1 Notion d'objet

#### Définition d'un objet

Nous désignons par le terme objet une entité anatomique nommée et définie.

#### Définition d'une aire

Nous appelons aire un objet définissant une région de l'espace, connexe et sans trou.

En particulier, une aire peut être formée par la réunion d'un objet connexe et de ses trous. De même, la réunion de deux aires connexes forme une nouvelle aire si aucun trou n'apparaît lors de cette réunion.

Par convention, si un objet est une aire de volume important son identificateur commence par  $A_{-}$  (Cf. tableau 1.1).

identificateur	aire
$A\_ACQ$	acquisition
$A\_CEN$	aire centrale
$A\_CVL$	cervelet
A_DIE	diencéphale
$A\_ENC$	encéphale
$A\_HMd$	hémisphère droit
$A\_HMg$	hémisphère gauche
$A\_ISM$	isthme
$A\_MET$	métencéphale
A_MOA	moelle allongée
$A\_MOE$	moelle épinière
$A\_NEE$	néencéphale
$A\_PAL$	paléencéphale
$A\_PNT$	pont cérébral
$A\_PRO$	prosencéphale
A_RHO	rhombencéphale
$A\_SBC$	aire sous-corticale
$A\_SNC$	système nerveux central
$A\_TEL$	télencéphale
$A\_TRC$	tronc cérébral
$A\_VEN$	aire ventriculaire
$A\_VER$	vermis

TAB. 1.1 – Objets de type "aire"

#### Définition d'une matière

Nous disons qu'une *matière* est l'ensemble des objets composés exclusivement d'une unique matière.

Pour un objet du cerveau, cette dernière est souvent soit la substance grise ou blanche, soit le liquide céphalo-rachidien. Pour un objet de la tête mais extérieur au cerveau, c'est généralement l'air, la peau, le muscle ou l'os.

Par convention, l'identificateur des matières principales (tableau 1.2) commence par  $M_{-}$ .

#### **Autres objets**

- La substance blanche du prosencéphale n'est pas une aire car les noyaux centraux y forment des trous.
- Le télencéphale est une aire par sa définition mais non une matière car il comporte en proportion importante les deux types de substance.
- L'encéphale privé du diencéphale n'est ni une aire ni une matière.
| identificateur | matière                   |
|----------------|---------------------------|
| M_AIR          | air                       |
| $M\_GRA$       | graisse                   |
| $M\_HVT$       | humeur vitrée             |
| $M\_LCR$       | liquide céphalo-rachidien |
| $M\_MUS$       | muscle                    |
| $M\_OS$        | os                        |
| $M\_PEA$       | peau                      |
| $M\_SNG$       | sang                      |
| $M\_SGR$       | substance grise           |
| $M\_SBL$       | substance blanche         |

TAB. 1.2 – Objets de type "matière"

Une remarque enfin : les petits objets (capsules, commissures, noyaux...) sont souvent à la fois aire et matière, leur identificateur ne porte donc pas de préfixe (tableau 1.3).

### **1.6.2** Mise en évidence des différents types de relation

Dans un domaine comme l'anatomie cérébrale où les structures interagissent fortement, vouloir les définir de manière absolue relève de l'utopie. Par conséquent, nous mettons en évidence les différents types de relations existant entre elles, relations qui devraient nous permettre de les décrire puis de les reconnaître.

#### **Relations ensemblistes**

Un objet pouvant être considéré comme un ensemble, nous utilisons naturellement les symboles ensemblistes classiques :

$$= \subset \cap \cup$$
.

Cependant, afin de caractériser des relations ensemblistes strictes entre deux objets, nous définissons quatre opérateurs binaires booléens mutuellement exclusifs. Leur rôle est de traduire les notions strictes d'égalité, d'inclusion, d'exclusion et d'intersection, notions qui ne peuvent pas coexister pour deux objets donnés A et B. Le tableau 1.4 présente leur symbolique, leur définition en termes ensemblistes et leurs propriétés ; le caractère 's' apposé au dessus des symboles signifie que ces relations sont strictes. On a donc :

$$\forall A \text{ et } B, \exists ! op \in \{\stackrel{s}{=}, \stackrel{s}{\subset}, \stackrel{s}{\frown}, \stackrel{s}{\cap} \} \text{ tel que } A \text{ op } B.$$

Trivialement, deux objets sont dits différents s'ils ne vérifient pas la relation d'égalité.

### **Relations directionnelles**

Aux termes directionnels utilisés en anatomie cérébrale, nous associons une symbolique que résume le tableau 1.5.

identificateur	matière
ADH	adhérence interthalamique
CAL	corps calleux
CAN	canal central
CAP	capsule
CAE	capsule externe
CAM	capsule extrème
CAI	capsule interne
CIT	citernes
CMA	commissure antérieure
CMI	commissure interhémisphérique
CSO	centre semi-ovale
CTX	cortex
CSO	centre semi-ovale
FNX	fornix
HYP	hypothalamus
MON	trou de Monro
NBA	noyaux de la base
NCA	noyau caudé
NCE	noyaux centraux
NLE	noyaux lenticulaires
PAL	pallidum
PUT	putamen
SCI	scissure interhémisphérique
SIL	sillons
SYL	aqueduc de Sylvius
THA	thalamus
VTL	ventricule latéral
VT3	ventricule III
VT4	ventricule IV

TAB. 1.3 – Autres objets

Pour caractériser la position relative de deux objets A et B vérifiant l'exclusion, nous définissons des opérateurs binaires booléens. Ainsi, l'opérateur relationnel :

$$A \uparrow B \tag{1.1}$$

signifie que A est plutôt dans une région supérieure  $\underline{\mathbf{a}} B$ .

L'emploi du terme *plutôt* dans la phrase précédente témoigne du fait que, contrairement aux relations ensemblistes, les relations directionnelles ne sont pas d'un formalisme précis. La déclaration d'une relation directionnelle entre deux objets est en fait une description vérifiée de manière globale et approximative [BLOC-96b]. En effet, un objet dit supérieur à un autre n'est pas *a priori* superposable exactement au second suivant la verticale. De plus, l'objet supérieur peut comporter des parties situées inférieurement comparativement à certaines parties de l'autre objet. Toute relation directionnelle doit donc être entendue au sens large. Nous verrons dans la partie IV comment des relations aussi approximatives peuvent être formalisées.

relation	symbolique	signification ensembliste	propriétés
égalité	$A \stackrel{\mathrm{s}}{=} B$	A = B	symétrique, transitive, réflexive
inclusion	$A \stackrel{\mathrm{s}}{\subset} B$	$A \neq B$ et $A \subset B$	transitive
exclusion	$A \stackrel{s}{\frown} B$	$A \cap B = \emptyset$	symétrique
intersection	$A \stackrel{\mathrm{s}}{\cap} B$	$A \cap B \notin \{ \emptyset, A, B \}$	symétrique

TAB. 1.4 – Opérateurs booléens de type ensembliste entre deux objets

TAB. 1.5 – Symbolique directionnelle

symbole	direction
$\uparrow$	supérieure
$\rightarrow$	inférieure
$\leftarrow$	antérieure
$\rightarrow$	postérieure
	médiale
$\triangleright$	latérale

Notons que par définition :

$$A \uparrow B \Rightarrow A \not \cap B, \tag{1.2}$$

et

$$A \uparrow B \Leftrightarrow B \downarrow A. \tag{1.3}$$

Pour caractériser la partie d'un objet déterminée par sa direction par rapport au reste de l'objet, nous utilisons un opérateur unaire. Nous notons la partie supérieure <u>de</u> A:

 $[A\uparrow]. \tag{1.4}$ 

Notons que par définition :

 $[A\uparrow] \stackrel{\rm s}{\subset} A,\tag{1.5}$ 

et

$$[A\uparrow]\uparrow[A\downarrow]. \tag{1.6}$$

De manière similaire, les définitions et propriétés (formules de (1.1) à (1.6)) sont appliquées aux six autres relations directionnelles.

Mise en garde : les implications du type  $(A \leftarrow [B \uparrow] \Rightarrow A \leftarrow B)$  ne sont pas systématiquement vraies (tout dépend de la façon dont les relations directionnelles sont formalisées).

### **Relations de distance**

Parler de la notion de distance entre objets sous-entend qu'une distance mathématique entre deux objets de forme quelconque a été définie de façon formelle [BLOC-95b] (voir en partie IV), ce que pour l'instant nous supposons.

Lorsque deux objets A et B sont en contact, la distance entre leurs surfaces en vis-à-vis est nulle localement. Toutefois, nous pouvons préciser la nature de ce contact en indiquant la morphologie locale à ce contact.

Si le contact entre A et B est plutôt ponctuel, nous écrirons :

$$A \Leftrightarrow B$$
.

En revanche, si le contact nous paraît plutôt surfacique, nous écrirons alors :

```
A \mid B.
```

Pour indiquer que deux objets A et B sont distants, nous écrirons :

$$A \overset{d}{\parallel} B$$

suivant que la distance moyenne entre les surfaces de A et B en regard est approximativement inférieure, égale ou supérieure à d.

#### 1.6.3 Raccourcis d'écriture

Nous proposons enfin deux raccourcis d'écriture :

$$A op1 op2 B \iff (A op1 B \text{ et } A op2 B),$$

et

 $A op1 B op2 C \iff (A op1 B et B op2 C),$ 

qui peuvent être combinés. Par exemple :

```
A \ op1 \ op2 \ B \ op3 \ C \iff (A \ op1 \ B \ et \ A \ op2 \ B \ et \ B \ op3 \ C).
```

## 1.7 Description des objets par leurs relations

Grâce aux différents symboles relationnels que nous avons définis, nous pouvons décrire efficacement les objets que nous avons présentés. Ces notations seront traduites, en particulier dans la partie IV, soit sous forme binaire, soit sous forme floue.

**Aires principales** 

$$A\_SNC = A\_MOE \cup \downarrow A\_TRC \cup A\_PRO$$



## $A\_MOE \mid \downarrow A\_MOA$

 $A\_MET = A\_PNT \cup A\_CVL$ 

 $A\_RHO = A\_MET \cup A\_MOA$ 

 $A\_PAL = A\_DIE \cup \parallel NBA \cup |CAP|$ 

 $A\_NEE = CTX \cup |CSO \cup |CAL|$ 

 $A\_PRO = A\_TEL \cup |A\_DIE|$ 

 $A\_DIE \uparrow |A\_ISM$ 

$$A\_TEL = A\_HMg \cup |A\_HMd$$

 $A\_PRO = A\_PAL \cup |A\_NEE$ 

 $A\_SNC \simeq A\_VEN \cup M\_SGR \cup M\_SBL \cup M\_SNG$ 

 $A\_VEN = M\_LCR \cap A\_SNC$   $A\_VEN = VL \cup \vdash MON \cup V3 \cup SYL \cup V4 \cup CAN$   $V3 = A\_VEN \cap A\_DIE$   $SYL = A\_VEN \cap A\_ISM$   $V4 = A\_VEN \cap A\_RHO$   $CAN = A\_VEN \cap A\_MOE$ 

Matières principales

$$M\_LCR = A\_VEN \cup CIT \cup SIL$$

$$M\_LCR \cap A\_PRO = A\_VEN \cap A\_PRO = VL \cup MON$$

$$M\_SGR \cap A\_PRO = CTX \cup NCE$$

$$NCE = NBA \cup THA \cup \uparrow HYP$$

$$NBA = NCE \cap A\_TEL$$

$$THA \cup HYP = NCE \cap A\_DIE$$

$$NBA = NCA \cup NLE$$

$$NLE = PUT \cup \rhd |PAL$$

$$ADH = [THAg\Box] \cup [THAd\Box]$$

 $M\_SBL \cap A\_PRO = M\_SBL \cap A\_TEL = CMI \cup CAP \cup CSO$ 

 $CMI = CMA \cup CAL$ 

$$CAP = CAI \cup CAE \cup CAM$$

## 1.8 Conclusion

Nous avons décrit dans ce chapitre l'ensemble des structures cérébrales anatomiques que nous serons amenés à manipuler dans la suite de ce manuscrit. D'une description anatomique individuelle de chaque structure, nous avons évolué vers une description relationnelle où les différents types de relations que nous avons distingués sont présentés de façon très binaire.

En revanche, la mise en œuvre voire la définition de certaines relations n'est pas obligatoirement binaire. Pour les relations directionnelles par exemple, nous avons insisté sur le fait qu'elles ne relèvent pas d'un formalisme précis ; leur expression se traduira alors dans le cadre de la théorie des ensembles flous (partie IV).

Si la description individuelle des structures est la base d'une reconnaissance morphologique (et cela sera exploité dans le chapitre 7 de la partie III), les relations sont primordiales pour les méthodes de segmentation et de reconnaissance contextuelles (partie III) et structurelles (partie IV).

# **Chapitre 2**

# L'observation en IRM cérébrale

Avec l'utilisation en routine clinique de l'imagerie par résonance magnétique, le praticien s'est familiarisé avec l'observation du contenu du cerveau, très particulière à ce type d'imagerie. Cette observation change radicalement de celle très académique des planches anatomiques dessinées ou des photographies de coupes anatomiques.

Ce chapitre a pour but de présenter les spécificités de l'observation des structures internes cérébrales dans les images numériques volumiques par résonance magnétique.

Après une présentation des images classiquement acquises en IRM (section 2.1), nous nous attachons à étudier les défauts potentiels de ces images dans la section 2.2 (bruit, dérive, volume partiel, artefacts). Nous discutons en particulier de la nécessité de prendre en compte ou non ces défauts dans le traitement de ces images. Dans la section 2.3, nous étudions la validité du modèle gaussien pour représenter la radiométrie des différentes structures et proposons une méthode d'apprentissage supervisé robuste.

## 2.1 Présentation des données

#### 2.1.1 Exemple d'une acquisition

Afin d'illustrer nos propos dans les pages suivantes, nous utilisons des coupes extraites de l'acquisition IRM tridimensionnelle pondérée en  $T_1$ :  $xavT_1$ . Cette acquisition d'un cerveau sain est issue d'un système IRM General Electric SIGNA; elle a été réalisée à 1,5T avec  $T_R = 23ms$  et  $T_E = 5ms$  à l'hôpital La Pitié-Salpétrière dans le service du Professeur Marsault.

Les figures 2.1, 2.2 et 2.3, en page 34 et suivantes, présentent respectivement l'ensemble des coupes axiales, coronales et sagittales de l'acquisition  $xavT_1$ . Les différentes aires du système nerveux central que nous avons rappelées en section 1.1.2 sont mises en évidence dans un éclaté figure 2.4. Différentes structures décrites dans le chapitre 1 sont montrées en figure 2.5.



FIG. 2.1 – Planche axiale de  $x a v T_1$ 

Les coupes du haut (resp. du bas) de cette figure correspondent à la partie inférieure (resp. supérieure) du cerveau. Dans chaque coupe, les lignes du haut (resp. du bas) correspondent à la partie antérieure (resp. postérieure) du cerveau et les colonnes centrales (resp. extrêmes, de gauche ou de droite) à la partie médiale (resp. latérales, de gauche ou de droite) du cerveau.



FIG. 2.2 – Planche coronale de  $xavT_1$ 

Les coupes du haut (resp. du bas) de cette figure correspondent à la partie antérieure (resp. postérieure) du cerveau. Dans chaque coupe, les lignes du haut (resp. du bas) correspondent à la partie supérieure (resp. inférieure) du cerveau et les colonnes centrales (resp. extrêmes, de gauche ou de droite) à la partie médiale (resp. latérales, de gauche ou de droite) du cerveau.



FIG. 2.3 – Planche sagittale de  $xavT_1$ 

Les coupes du haut et du bas (resp. du milieu) de cette figure correspondent aux parties latérales (resp. médiale) du cerveau. Dans chaque coupe, les lignes du haut (resp. du bas) correspondent à la partie supérieure (resp. inférieure) du cerveau et les colonnes de gauche (resp. de droite) à la partie antérieure (resp. postérieure) du cerveau.



FIG. 2.4 – Eclaté du système nerveux central

Cet éclaté, qui correspond à la vue sagittale de la figure 2.5, détaille les aires du système nerveux central décrites en section 1.1.2.

## 2.1.2 Acquisition clinique

### Pondération

Les acquisitions d'images par résonance magnétique dépendent de deux paramètres réglables cliniquement:  $T_R$ , temps de répétition des séquences d'impulsions, et  $T_E$ , temps d'écho. Une acquisition effectuée avec des temps  $T_R$  et  $T_E$  courts est dite en  $T_1$  (temps de relaxation spin-réseau). Lorsque ces deux temps sont longs, elle est dite en  $T_2$  (temps de relaxation spin-spin). Et lorsque  $T_R$ est long et  $T_E$  court, elle est dite en  $\rho$  (densité de protons).

Toute acquisition peut être caractérisée par rapport à ces trois types particuliers. Ainsi, on parle d'image pondérée en  $T_1$  si l'acquisition se rapproche plus du type d'acquisition en  $T_1$  que des deux autres types ; de façon similaire, on parle d'image pondérée en  $T_2$  ou en  $\rho$ .

L'image  $xavT_1$  a donné lieu à trois acquisitions: une première, pondérée en  $T_1$ , et deux autres en  $T_2$ , pondérées différemment (figure 2.6).

#### Pratiquement

Dans les images en  $T_1$ , on observe du plus foncé au plus clair :

- l'air, les yeux, l'os et le liquide céphalo-rachidien,
- les muscles, la peau et la substance grise,
- la substance blanche,
- la graisse et le sang.

En  $T_2$ , toujours du plus foncé au plus clair, on observe :

- l'air, l'os et le sang,
- les muscles et la peau,
- la substance blanche,
- la substance grise,
- la graisse, les yeux et le liquide céphalo-rachidien.



FIG. 2.5 – Coupe sagittale  $n^{\circ}90$  de  $xavT_1$ 

Observation en IRM et schéma des structures suivantes : corps calleux (1), septum pellucidum (2), plexus choroïde (3), adhérence interthalamique (4), troisième ventricule (5) et quatrième ventricule (6).



FIG. 2.6 – Acquisitions multiples

Même coupe axiale extraite de trois acquisitions d'un volume 3D :  $xavT_1$ ,  $xavT_{2a}$  et  $xavT_{2b}$  (de haut en bas); trois différences majeures apparaissent entre l'acquisition en  $T_1$  et celles en  $T_2$ : l'échantillonnage, la localisation de la tête et la radiométrie.

Ces deux ordres sont donnés à titre indicatif; il se peut qu'avec des réglages particuliers les niveaux radiométriques de certaines structures suivent un ordre légèrement différent.

#### 2.1.3 A propos du numérique

Les données IRM 3D sont numériques, ce qui signifie échantillonnées et quantifiées.

#### Échantillonnage

L'échantillonnage suit une trame régulière inscrite dans un volume cubique. A chaque nœud de trame correspond un point volumique de l'image, ou voxel. Dans les acquisitions classiques en neuroanatomie, l'empilement des voxels forme le volume non lacunaire de l'image.

Une image 3D peut être vue dans les trois directions comme une succession de coupes, respectivement axiales, coronales et sagittales. La trame est souvent isotrope dans le plan de coupe avec un pas généralement proche du millimètre (les mesures ont lieu quelquefois de façon anisotrope mais le système d'acquisition restitue au final l'isotropie par interpolation). En revanche, la hauteur des voxels, pas de trame perpendiculaire au plan de coupe, dépasse dans la plupart des cas le millimètre.

C'est le cas par exemple de l'acquisition  $xavT_1$  dont la hauteur d'un voxel est en fait 1,3 fois ses autres dimensions dans le plan de coupe axial; les planches montrées en pages 35 et 36 corrigent l'anisotropie par un facteur d'échelle vertical.

Pour être comparées, plusieurs images 3D d'une même région anatomique doivent coïncider exactement ; tout nœud de trame dans chaque image doit correspondre à un même point de l'espace observé.

Malheureusement, il est rarement possible de garantir que le sujet n'ait pas bougé entre les différentes acquisitions. Il faut alors trouver la transformation géométrique qui permette la mise en correspondance des images [VANE-93]. Une telle transformation est rigide lorsque les pas de trame dans les trois directions sont connus puisque le recalage peut être effectué dans l'espace de métrique réelle; dans le cas contraire, trois facteurs d'échelle doivent être déterminés.

De plus, d'une acquisition à une autre, le pas de trame et le nombre de couches dans chaque direction peuvent varier. Il faut alors effectuer un rééchantillonnage pour que les trames de chaque image se superposent [VAND-91].

En  $T_1$ , l'obtention d'une coupe étant rapide, on peut se permettre d'en acquérir un nombre important; il en résulte que les voxels sont très souvent presque isotropes. En  $T_2$  en revanche, un temps supérieur est nécessaire à l'obtention d'une coupe; leur nombre est donc généralement plus faible qu'en  $T_1$  et l'épaisseur des coupes souvent importante, de l'ordre de plusieurs millimètres.

Lorsque nous parlons d'acquisitions multiples, nous considérons que ces prétraitements ont été réalisés et donc que les voxels sont comparables d'une image à une autre pour un même patient. En particulier pour l'image xav (figure 2.6 page 39), nous avons mis en œuvre ces prétraitements.

Pour xav, nous connaissions les dimensions des voxels dans chaque acquisition:  $1 mm \times 1 mm \times 1$ , 3 mm pour  $xavT_1$  et  $1 mm \times 1 mm \times 3 mm$  pour  $xavT_{2a}$  et  $xavT_{2b}$ . Après que nous avons segmenté le cerveau dans les trois acquisitions (voir en section 7.2), nous avons déterminé les deux transformations rigides à appliquer au cerveau de  $xavT_1$  pour le mettre en correspondance avec les cerveaux segmentés respectivement dans  $xavT_{2a}$  et  $xavT_{2b}$ ; pour cela, nous avons mis en œuvre l'algorithme de Besl et McKay [BESL-92] (voir en section 9.2.3).

Comme la résolution diffère entre l'acquisition en  $T_1$  ( $256 \times 256 \times 124$  voxels) et les acquisitions en  $T_2$  ( $256 \times 256 \times 44$  voxels), nous avons dû effectuer un rééchantillonnage; connaissant la transformation rigide à appliquer aux voxels de l'acquisition en  $T_1$  pour avoir son correspondant dans

chaque autre acquisition, nous avons alors effectué une interpolation trilinéaire pour obtenir avec le même échantillonnage que  $xavT_1$  les images recalées  $xavT_{2a}$  et  $xavT_{2b}$ .

Nous avons ainsi effectué deux choix :

- nous conservons le meilleur échantillonnage des trois acquisitions initiales,
- le rééchantillonnage est trilinéaire.

Le premier choix garantit que l'acquisition d'échantillonnage de référence ne soit pas prétraitée; c'est heureux car c'est l'aquisition qui porte *a priori* le plus d'informations. Le second choix se justifie par le facteur relativement faible entre le nombre de coupes de l'aquisition de référence et celui des autres aquisitions (environ 1/2,3); une interpolation plus poussée n'aurait pas augmenté significativement la qualité du résultat.

#### Quantification

Tout voxel contient une information numérique, intégration d'une mesure physique de radiométrie sur le volume du voxel et quantifiée sur un certain nombre de bits; pour les acquisitions standards, il est généralement de 16 dont 12 utiles. Afin de réduire la taille mémoire du stockage d'un volume-image, nous nous restreignons systématiquement à une quantification de 8 bits<sup>1</sup>.

Les images radiométriques n'exploitent pas toujours toute la dynamique des niveaux de gris; lorsque l'information pertinente est contenue entièrement dans une plage de 256 niveaux de gris, nous pouvons éviter la requantification en recentrant la dynamique dans l'intervalle 0-255 et en saturant à 0 ou 255 les niveaux respectivement négatifs ou trop élevés. Ces niveaux saturés doivent correspondre à des voxels de structures sans importance pour notre problème de segmentation. C'est le cas par exemple avec  $xavT_1$  où seuls les vaisseaux sanguins ont des niveaux radiométriques supérieurs à 255 (Cf. figure 2.7).

Si en revanche, l'information pertinente a une dynamique supérieure à 256 niveaux, nous sommes obligés de requantifier les niveaux de gris. La perte d'information qui en résulte consiste alors en une dégradation de la précision radiométrique de la description des différents tissus. Cette dégradation peut porter à conséquence lorsque la séparation radiométrique entre structures est déjà faible dans l'image sur 16 bits, les structures en question devenant d'autant moins discriminables que la dynamique doit être réduite. Les images que nous avons utilisées échappent à cette règle ; nous les avons donc requantifiées sans crainte (Cf. figure 2.8).

#### 2D contre 3D

Avec des images 2D, il ne vient pas à l'esprit d'effectuer des traitements sur les lignes puis d'abouter les résultats obtenus le long des colonnes ; on considère que l'information est véritablement bidimensionnelle. Le parti pris que nous avons adopté pour ce travail de recherche suit ce même raisonnement : nous traitons les images tridimensionnelles sans favoriser une direction d'échantillonnage particulière parmi les trois<sup>2</sup>. De ce parti pris résultent plusieurs conséquences que nous exposons en annexe A.

<sup>1.</sup> Pour avoir en tête un ordre de grandeur simple, une image 3D possédant  $256 \times 256 \times 128$  voxels codés sur 8 bits pèse 8 Mo.

<sup>2.</sup> Cette assertion est vraie à une exception près : l'étape 7 section 7.2.1 page 158 est un bouchage de trous **bi**dimensionnel qui suppose que l'acquisition a un plan de coupe axial; cependant, cette étape particulière n'est pas indispensable dans la chaîne de traitements dans laquelle elle s'insère.



FIG. 2.7 – Saturation de la dynamique à 8 bits

Cette figure représente l'histogramme de l'IRM 3D  $xavT_1$  après saturation de la valeur des niveaux de gris des voxels à 255. On observe par la petitesse du pic de l'histogramme à 255 que très peu de voxels de l'acquisition sur 16 bits possédaient un niveau de gris supérieur à 255 (moins de 0,03 % de l'ensemble des voxels de l'image). Ces voxels, correspondant au sang des vaisseaux cérébraux, ne sont pas importants pour notre problème de segmentation ; la perte d'information due au passage de 16 à 8 bits est sans conséquence.



FIG. 2.8 – Réduction de la dynamique à 8 bits

Cette figure représente l'histogramme de l'IRM 3D  $xavT_{2a}$  avant et après réduction de la dynamique à 255 niveaux de gris.

*Nota bene :* lorsque nous illustrons un résultat dans ce manuscrit, nous montrons souvent une vue axiale, mais les données utilisées sont implicitement toujours tridimensionnelles tout comme les méthodes et traitements conduisant à ce résultat.

## 2.2 Défauts des images en IRM 3D

De nombreux facteurs affectent l'apparence des images en IRM. Nous nous contentons ici de les mettre en évidence; nous ne les étudions pas en détail car ils ne sont pas fondamentaux pour les méthodes proposées par la suite.

## 2.2.1 Bruit

Un des défauts inhérents à tout système de mesure est le bruit. Son origine est généralement multiple, chaque élément du système contribuant de façon plus ou moins significative au bruit observé dans les mesures finales et donc, dans les objets observés.

## Lisibilité et bruit

En IRM, la lisibilité des images est intimement liée au rapport signal/bruit, au contraste et à la résolution. On observe que :

- la force du champ magnétique augmente le contraste grâce à l'effet de Boltzman,
- l'accroissement de la largeur de la bande passante du système de mesure permet d'obtenir les transitions radiométriques brutales mais augmente le bruit et l'effet de Gibbs,
- doubler la taille du voxel diminue la résolution mais multiplie par  $\sqrt{8}$  le rapport signal/bruit,
- le moyennage du signal après avoir multiplié par huit le nombre d'excitations double le rapport signal/bruit mais octuple le temps de l'acquisition.

#### **Observation du bruit**

Pour observer le bruit, il est nécessaire de trouver dans l'image des régions uniformes, c'est-àdire composées d'une matière unique et homogène, et de taille relativement importante. De tels sousvolumes sont rares dans les images IRM 3D; la réunion {centre semi-ovale/corps calleux (substance blanche)} en vue sagittale nous a paru idéale pour cette observation. L'image 2.9, contrastée pour mieux visualiser la texture du bruit, en est extraite.



FIG. 2.9 – Observation du bruit

Cette région d'intérêt correspond au centre semi-ovale vu d'une coupe sagittale; on peut y observer le bruit qui entache l'uniformité radiométrique de la substance blanche.

Remarquons enfin que les coupes axiales supérieures sont marquées par un phénomène de repliement qui intervient lors de la reconstruction de l'image : elles possèdent un écho des coupes axiales inférieures appelé fantôme (Cf. planche 2.1).

## Filtrage

Une première idée pour atténuer le bruit en IRM 3D est d'avoir recours aux filtres traditionnels de traitement d'images numériques. Cependant, le plus petit noyau d'un filtre symétrique et tridimensionnel est de taille relativement importante comparativement à celle des petites structures anatomiques. Ce filtre, constitué par un voxel et ses six voisins (deux dans chaque dimension) a donc un volume de 9, 1 mm<sup>3</sup> en ce qui concerne l'image  $xavT_1$ .

Sur la figure 2.10, on peut observer le résultat des filtres moyenneur, médian et diffuseur anisotrope [PERO-90], appliqués à une acquisition  $xavT_1$  (indépendemment des autres acquisitions dont nous disposons). Le premier rend l'image trop floue ; le second donne un lissage correct, respectant les contours ; le troisième, beaucoup plus coûteux en temps de calcul car itératif, ne donne pas de bien meilleurs résultats (il a été appliqué en IRM cérébrale dans [GERI-92] et [KIKI-96]).



FIG. 2.10 – Filtrages classiques contre le bruit

Des filtres débruiteurs classiques ont été appliqués à une image 3D; cette figure représente une même région d'intérêt d'une coupe de l'image originale (à gauche) puis des images après traitement par un filtre linéaire (moyenneur) et deux non linéaires, un filtre de rang médian et un filtre diffuseur anisotrope.

Une seconde idée pour atténuer le bruit est de recourir au filtrage linéaire lorsque l'image fait l'objet de plusieurs acquisitions. Il s'agit alors de calculer les pondérations des combinaisons linéaires appliquées aux acquisitions initiales pour obtenir de nouvelles vues de l'image, vues qui maximisent le rapport contraste/bruit sur certaines régions [SOLT-96].

De façon pragmatique, le bruit sera pris en compte implicitement par la modélisation statistique des lois radiométriques ; nous n'utiliserons donc pas de filtrage comme prétraitement.

### 2.2.2 Dérive

Du fait d'un défaut éventuel de non-uniformité du champ magnétique, les niveaux de gris d'une image 3D peuvent dériver le long d'une direction quelconque de l'image. Conséquemment, la radiométrie des structures cérébrales peut varier spatialement ce qui constitue une difficulté supplémentaire pour le traiteur d'images.

## Littérature

La correction de l'hétérogénéité de l'intensité radiométrique des images par résonance magnétique a donné lieu à de nombreux travaux de recherche. Nous ne citons délibérément que deux méthodes, choisies pour leur approche purement « traitement d'images » (elles ne s'appuient que sur l'image pour la corriger).

Vannier *et al.* [VANN-85] décrivent une méthode de correction fondée sur l'examen des histogrammes de chaque couche de l'image. Cette méthode suppose donc que la distortion radiométrique suit une des trois directions d'échantillonnage ce qui est une approximation grossière, l'hétérogénéité se traduisant plus précisément par des fonctions tridimensionnelles polynomiales de degré deux.

Lim *et al.* [LIM-89] proposent une technique de lissage radial, centré sur le cerveau, restreint au cerveau, et utilisant un large noyau gaussien. L'image ainsi lissée est supposée refléter l'hétérogénéité du champ magnétique et permet alors de corriger l'acquisition.

Malgré les améliorations apportées aux techniques d'imagerie par résonance magnétique, les problèmes liés à l'hétérogénéité du champ magnétique et au réglage de l'appareil subsistent et font l'objet de parutions récentes [LANG-97b]. Aussi, afin de savoir si les images que nous manipulons présentent ce défaut, nous mettons en œuvre un protocole très simple de test.

#### Protocole de mesure de la dérive

Afin de tester l'éventuelle présence d'une dérive radiométrique dans l'image, nous supposons initialement que celle-ci ne présente pas ce défaut; puis, une fois l'image segmentée, nous vérifions la légitimité de cette hypothèse. Pour cela, nous traçons l'évolution du niveau de gris moyen de certaines structures, d'une couche à l'autre, et dans les trois directions de l'échantillonnage. Si nous n'observons aucune dérive, le test est négatif.

Pour que les moyennes soient significatives d'un point de vue statistique, il est nécessaire que le nombre de points d'une structure donnée dans les couches utilisées soit suffisamment important. Il faut donc choisir pour ce test une structure relativement grande ; de nouveau, nous faisons appel à la substance blanche et nous nous limitons aux couches où elle est fortement représentée, afin d'assurer les statistiques obtenues.

#### Résultats

Dans les images à notre disposition, nous constatons des écarts de l'ordre d'un niveau de gris entre les moyennes radiométriques d'une même structure le long des coupes axiales, coronales et sagittales. Ces écarts ne nous semblent pas suffisamment significatifs pour que nous puissions parler de dérive (voir figure 2.11); ils sont probablement dus à l'effet de volume partiel qui fait l'objet de la section suivante.

Nous considérons donc que les acquisitions dont nous disposons ne présentent pas ce défaut.

#### 2.2.3 Mélange et effet de volume partiel

Un problème inhérent à tout système numérique d'imagerie est l'effet de volume partiel. Si la surface entre plusieurs objets intersecte un voxel, la mesure radiométrique sur ce voxel résulte d'un mélange des contributions radiométriques des objets présents dans ce voxel.



FIG. 2.11 – Radiométrie de la substance blanche le long des coupes axiales

Cette courbe montre la variation de la radiométrie d'une structure le long d'un axe de coupe de l'image 3D; une telle variation n'est pas significative d'un défaut de dérive.

#### A propos de la résolution

Lorsque la résolution de l'image augmente, le nombre relatif de voxels de mélange diminue ce qui permet d'obtenir de meilleures statistiques sur les tissus et une plus grande finesse dans la visualisation des structures. Grâce à la réalisation de matériels d'imagerie par résonance magnétique générant des champs de 1, 5 T, la résolution a été considérablement améliorée.

Cependant, la résolution courante reste encore trop faible comparativement à la petitesse de certaines structures cérébrales ; au mieux, de l'ordre du millimètre pour une acquisition complète de la tête. De plus, certaines acquisitions ont pour contrainte d'être effectuées dans un temps le plus bref possible : dans le cas de l'examen clinique d'enfants par exemple, où il est impossible de demander au patient de rester une demi-heure sans bouger. Aussi, certaines images contiennent des coupes axiales dont l'épaisseur peut atteindre le centimètre ; autant dire que les points de l'image sont alors presque tous des points de mélange.

#### Observations

Sur l'image 2.12, on remarque que la transition ventricule (foncé) / substance blanche (claire) est progressive en niveaux de gris. Cette transition témoigne d'un effet de mélange dû à la taille des voxels et au positionnement de la surface séparatrice des deux structures.

## 2.2.4 Artefacts

#### Décalage chimique

S'il est un artefact propre à l'IRM, c'est bien le décalage chimique. Il se produit quand les noyaux dans des environnements chimiques différents ont des fréquences de Larmor différentes. Cela se traduit dans l'image finale par un décalage spatial de l'observation des tissus dans la direction du codage de fréquence et donc, par l'apparition de faux contours.

Cet artefact est extrêmement prononcé à la frontière entre la graisse et l'eau comme on peut le constater sur l'image 2.13. En revanche, dans le cerveau, du fait du petit nombre de triglycérides, il ne se manifeste pas.

Ce défaut peut disparaître si l'on emploie des séquences d'acquisition particulières, dérivées de la séquence d'échos multiples de Carr-Purcell-Meiboom-Gill et utilisant des gradients variant dans



FIG. 2.12 – Visualisation de volumes partiels dus à l'effet de mélange

L'effet de volume partiel se traduit par l'apparition d'un dégradé radiométrique à l'interface entre deux structures ; pour une structure de taille relativement faible, la proportion de volumes partiels peut être plus importante que celle des voxels purs.



FIG. 2.13 – Observation du décalage chimique

Dans cette partie d'une vue axiale (extraite de l'acquisition  $TimT_1$ ), la peau, de chaque côté de l'image, contient successivement une bande sombre puis une bande claire.

le temps. Pour plus de détails, le lecteur peut se référer à [CHO-88].

### Mouvements

Les mouvements répertoriables lors d'une acquisition clinique sont de deux natures :

- périodiques, comme le flux du sang et du liquide céphalo-rachidien, les battements cardiaques ou la respiration,
- ou aléatoires, comme les déplacements du patient.

Ils produisent dans les images des artefacts nuisibles, se traduisant par des échos très facilement identifiables. Notons que les récentes techniques d'imagerie rapide tendent à réduire de façon significative ce défaut.

Les artefacts de mouvement font l'objet d'études abondantes. Comme nous ne nous occuperons pas de la correction de ce défaut, citons seulement pour référence certaines de ces études.

Certaines émettent des hypothèses quant au type de mouvement : déplacement linéaire et de vitesse connue, déplacement périodique le long d'un axe connu, expansion linéaire, combinaison d'un déplacement et d'une expansion linéaires. D'autres sont plus générales : par restauration de phase, par décalage de spectre ou plus récemment par une combinaison des deux. Le lecteur peut se reporter à [ZORO-95] qui propose une courte revue de ces études, ou à [ATKI-97] un peu plus récemment.

# 2.3 Modélisation radiométrique des classes

Malgré tous leurs défauts radiométriques, les images IRM sont aujourd'hui de bonne qualité et de nombreuses structures cérébrales sont discriminables à l'œil.

#### 2.3.1 Consensus gaussien

Dans une image sans dérive, chaque structure de volume important semble être représentée en IRM par un niveau de gris uniforme, aux autres défauts près. Cette certaine homogénéité radiométrique reflète celle de la matière biologique constitutrice de la structure en question, que cette matière soit composite ou non.

La radiométrie associée à une structure peut faire l'objet d'une étude statistique afin d'être éventuellement modélisable par une loi. Cette loi décrirait alors la probabilité d'obtenir tel niveau de gris (dans chaque acquisition) en prenant au hasard un voxel de cette structure.

De la littérature ressort un consensus : chacune des matières cérébrales se traduit en IRM par une loi radiométrique gaussienne. Chaque matière serait donc caractérisée, d'une part par sa moyenne radiométrique m, scalaire ou vecteur, et d'autre part par son écart-type radiométrique  $\sigma$  ou par sa matrice de covariance radiométrique  $\sum$ , si l'on dispose d'une acquisition IRM respectivement unique ou multiple.

Bien que le bruit des images par résonance magnétique ne soit pas vraisemblablement gaussien et additif, cette hypothèse va nous permettre de mettre en œuvre une panoplie de méthodes *ad hoc* dans les parties suivantes de ce manuscrit.

## 2.3.2 Protocole de validation de l'hypothèse gaussienne

Afin de valider l'hypothèse de la modélisation gaussienne de la radiométrie des structures, nous avons mis en œuvre un protocole expérimental.

#### Protocole d'apprentissage

La première étape de ce protocole consiste à demander à un expert de dessiner l'intérieur d'une structure donnée. Les dessins sont réalisés à la souris à l'aide d'un outil lasso sur des planches de couches, axiales, coronales et sagittales. Ce procédé est alors répété pour une autre structure.

Cette stratégie s'appuie sur plusieurs points :

- la demande explicite de ne pas tenir compte des voxels trop proches de frontières est motivée par la volonté de laisser à l'écart les voxels qui risquent d'être des voxels de mélange,
- aucun outil de détermination automatique de régions (par croissance à partir d'un point par exemple) n'est utilisé afin de ne pas biaiser l'expertise,
- dessiner une même structure sur une planche comportant toutes les couches autorise l'expert à vérifier la cohérence de son dessin en s'aidant de l'enchaînement des couches,
- dessiner une même structure trois fois, car vue sous trois angles différents (et orthogonaux), nous permet de nous assurer de la justesse de l'expertise en vérifiant la cohérence des trois dessins.

A l'issue de l'étape de dessin, nous ne gardons que les points redondants, c'est-à-dire, les points qui sont identifiés dans les trois dessins comme appartenant à la structure considérée. Les points douteux ainsi mis de côté, on calcule l'histogramme des points restants auquel on peut appliquer les tests statistiques.

Les distributions radiométriques sous-jacentes sont représentatives de voxels purs car notre protocole élimine implicitement les voxels de mélange.

#### **Tests statistiques**

Le caractère gaussien d'une distribution peut être mis en évidence grâce aux coefficients d'asymétrie et d'aplatissement. En effet, pour une telle distribution, les valeurs théoriques de ces coefficients sont respectivement :

$$\gamma_1 = \frac{\mu_3}{\sigma^3} = 0$$

et

$$\gamma_2 = \frac{\mu_4}{\sigma^4} = 3,$$

où  $\mu_k$  est le moment centré d'ordre k de cette distribution et  $\sigma = \sqrt{\mu_2}$  son écart-type.

Pour toute distribution statistique, l'estimation de la moyenne et de l'écart-type ne peut être validée que si le nombre n d'individus est suffisamment grand. Voyons ce qu'il en est pour nos ensembles d'apprentissage dans le cadre de la loi gaussienne.

Notons P la probabilité, à écart-type  $\sigma$  connu, pour que la moyenne recherchée  $v_r$  appartienne à un intervalle de confiance  $\Delta v$  centré sur v, moyenne estimée ; P s'écrit :

$$P\left( \left| v_r \Leftrightarrow v \right| < \frac{\Delta v}{2} \mid \sigma 
ight).$$

Le nombre minimal  $n_{min}$  de voxels nécessaires pour que P soit supérieure à une certaine valeur  $1 \Leftrightarrow \alpha$  vérifie :

$$n_{min} = 4 \left(\frac{u_{\alpha/2} \sigma}{\Delta v}\right)^2,$$

avec u fractile de la loi normale réduite [SAPO-90].

Nous avons mené ces calculs pour une probabilité de 0,95 et de 0,99; les résultats sont regroupés dans les tableaux 2.1 et 2.2.

#### Résultats des tests

Pour une structure donnée, une fois son ensemble d'apprentissage obtenu, nous calculons le taux de voxels retenus dans chaque planche, c'est-à-dire, pour la structure en question, le nombre de voxels de son ensemble d'apprentissage sur le nombre de voxels de son dessin dans cette planche. Ces taux, reportés dans le tableau 2.3, sont extrêmement révélateurs.

D'une part, ils nous apprennent que les structures ne sont pas perçues de la même façon dans les trois vues. Le ventricule latéral, par exemple, est mieux déterminé dans la vue coronale que dans les autres vues. Cela s'explique parce qu'il est perpendiculaire à cette vue, et qu'alors, le plexus choroïde qu'il contient est plus facilement discriminable.

$\sigma \Delta v$	0.5	1.0	1.5	2.0
2	246	61	27	15
3	553	138	61	35
4	983	246	109	61
5	1537	384	171	96
6	2213	553	246	138
7	3012	753	335	188
8	3934	983	437	246
9	4979	1245	553	311
10	6147	1537	683	384

TAB. 2.1 – Taille de confiance d'un ensemble d'apprentissage (P = 0.95)

Ce tableau indique, pour un écart-type  $\sigma$  donné, le nombre de voxels nécessaires pour que la moyenne estimée appartienne, avec une probabilité de 0.95, à un intervalle de confiance  $\Delta v$  exprimé en niveau de gris et centré sur la moyenne estimée.

TAB. 2.2 – Taille de confiance d'un ensemble d'apprentissage (P = 0.99)

$\sigma \backslash \Delta v$	0.5	1.0	1.5	2.0
2	425	106	47	27
3	955	239	106	60
4	1698	425	189	106
5	2654	663	295	166
6	3822	955	425	239
7	5202	1300	578	325
8	6794	1698	755	425
9	8599	2150	955	537
10	10616	2654	1180	663

Ce tableau est équivalent au tableau 2.1 mais pour une probabilité de 0.99; on note que le nombre de voxels nécessaires à une meilleure confiance (P = 0.99 au lieu de P = 0.95) dans les moyennes calculées statistiquement est pratiquement doublé.

D'autre part, ils nous montrent quelles sont les structures dont l'identification ne pose aucun problème. Plus la moyenne des taux est forte, moins la forme de la structure est ambiguë *de visu*.

Le tableau 2.4 donne la cardinalité et les valeurs des coefficients de forme, asymétrie et aplatissement, pour les différents ensembles d'apprentissage de l'image  $xavT_1$ .

D'après les tables des valeurs critiques de ces coefficients (tables A1.15 et A1.16 de [SAPO-90]), nous observons que les valeurs que nous avons obtenues eu égard au nombre d'échantillons tombent dans des intervalles attendus pour une loi gaussienne. Rien ne s'oppose donc à l'hypothèse suivant laquelle la radiométrie des classes peut être modélisée par une loi gaussienne.

structure	nombre de	taux	taux	taux	taux
	voxels retenus	axial	coronal	sagittal	moyen
ventricule latéral	1314	0.52	0.68	0.49	0.56
noyau caudé	3464	0.80	0.75	0.59	0.71

TAB. 2.3 – Sélection des ensembles purs d'apprentissage dans  $xavT_1$ 

TAB. 2.4 – Tests de gaussienneté des ensembles purs d'apprentissage de  $xavT_1$ , de  $xavT_{2a}$  et de  $xavT_{2b}$ 

structure dans $xavT_1$	nombre de voxels	asymétrie	aplatissement
putamen	5565	-0.29	3.06
ventricule latéral	1314	-0.01	3.24
noyau caudé	3464	-0.02	2.96
substance blanche	65742	0.11	3.15
muscle	10898	0.10	3.12
structure dans $xavT_{2a}$	nombre de voxels	asymétrie	aplatissement
putamen	2413	0.10	2.90
ventricule latéral	3659	-0.19	3.02
noyau caudé	2932	0.07	3.09
pallidum	984	0.01	2.87
structure dans $xavT_{2b}$	nombre de voxels	asymétrie	aplatissement
putamen	2413	-0.38	3.55
ventricule latéral	3659	0.41	4.93
noyau caudé	2932	-0.64	3.80
pallidum	984	0.18	3.10

#### **Estimations statistiques**

A la lumière des résultats précédents, nous considérons qu'avec le protocole employé, les statistiques obtenues sont précises et robustes. Ce seront nos statistiques de référence, regroupées dans le tableau 2.5.

## 2.4 Conclusion

Notre but est de reconnaître les différentes structures cérébrales dans des images par résonance magnétique tridimensionnelle, et cela, de la façon la plus automatique possible. La figure 2.14 qui montre une région du paléencéphale en vue axiale illustre la difficulté d'une telle tâche ; les structures n'apparaissent clairement qu'en éloignant notre regard de cette image.

Les causes fondamentales qui entraînent une mauvaise visibilité voire une absence de visibilité de certaines structures cérébrales en IRM sont au nombre de deux (la majorité des problèmes résultent en fait d'une combinaison de ces deux causes).

 La première cause est liée à la radiométrie. Si les radiométries respectives de deux structures adjacentes sont trop proches, même l'expert ne pourra déterminer correctement la frontière

structure dans $x a v T_1$	moyenne	écart-type	nb.voxels	$\Delta v$
putamen	66.3	5.75	5565	< 0.5
ventricule latéral	16.0	5.11	1314	< 1.0
noyau caudé	62.0	4.98	3464	< 0.5
substance blanche	79.8	4.54	65742	< 0.5
muscle	57.8	7.48	10898	< 0.5
structure dans $xavT_{2a}$	moyenne	écart-type	nb.voxels	$\Delta v$
putamen	62.7	8.47	2413	< 1.0
ventricule latéral	180.0	26.89	3659	< 2.5
noyau caudé	68.7	8.56	2932	< 1.0
pallidum	43.8	7.38	984	< 1.5
structure dans $xavT_{2b}$	moyenne	écart-type	nb.voxels	$\Delta v$
putamen	170.4	9.29	2413	< 1.5
ventricule latéral	189.5	14.94	3659	< 1.5
noyau caudé	174.0	10.29	2932	< 1.5
pallidum	148.3	9.12	984	< 2.0

TAB. 2.5 – Statistiques radiométriques pures obtenues par apprentissage

La colonne  $\Delta v$  donne, pour la valeur d'écart-type mesurée sur chaque ensemble d'apprentissage, l'intervalle de confiance (à P = 0.99) de la mesure de la moyenne sur chaque même ensemble.

Pour chaque distribution radiométrique, on ne connaît que l'écart-type mesuré; l'intervalle de confiance de la moyenne est lu dans le tableau 2.2 en considérant la ligne correspondant à l'écart-type immédiatement supérieur à celui mesuré. La valeur mesurée est donc par excès.

Rappelons enfin que ces statistiques ne concernent que des voxels purs, c'est-à-dire excluent la contribution des voxels de mélange; elles ne tiennent donc pas compte de l'effet de volume partiel.

entre ces deux structures. Deux facteurs augmentent cette difficulté : l'effet de volume partiel qui rend « floue » toute frontière ; et le bruit qui « rapproche » les deux radiométries.

– La seconde cause de mauvaise visibilité est liée à la taille des structures. Si celle-ci est de l'ordre des dimensions du voxel, la présence de ces structures, victimes de l'effet de volume partiel, peut passer pour une manifestation du bruit. Pire, si cette structure servait d'interface entre deux autres structures, ces dernières risquent d'être, à leur tour, difficilement séparables.

La visibilité d'une structure en IRM est donc une notion très relative qui dépend, d'une part, du rapport existant entre la morphologie de la structure et la résolution de l'acquisition, et d'autre part, des contextes spatial et radiométrique de la structure.



FIG. 2.14 – Zoom d'une partie de coupe axiale en IRM 3D

# Conclusion

Dans cette première partie, nous avons tout d'abord présenté un certain nombre de structures anatomiques cérébrales pour, par la suite, les décrire à l'aide d'un ensemble de relations (section 1.7). Ces relations sont de différents types : ensemblistes, directionnelles, relatives à une distance.

Enfin, ces structures étant observables en imagerie numérique tridimensionnelle par résonance magnétique, les spécificités de ce type d'imagerie ont été détaillées. Nous retiendrons que les deux défauts entachant nos acquisitions IRM sont le bruit et l'effet de volume partiel, et que la radiométrie d'une structure dans une acquisition IRM peut être modélisée par une loi gaussienne.

Deuxième partie

# **Classification non contextuelle**

# Introduction

Dans cette partie, nous nous proposons d'évaluer les apports de méthodes de reconnaissance de formes à la classification des différentes matières cérébrales en imagerie par résonance magnétique tridimensionnelle, à partir des niveaux radiométriques de ces images. Le but de cette partie n'est bien sûr pas d'étudier exhaustivement les méthodes possibles, mais d'illustrer, des méthodes classiques de divers types, leur mode d'application à notre problème, les résultats qu'elles permettent d'obtenir, les informations que nous pouvons en tirer pour des traitements ultérieurs, et leurs limites.

Ce chapitre introductif explique comment notre problématique de segmentation et reconnaissance peut s'incrire dans le cadre de la classification (chapitre 3); les chapitres suivants évaluent la performance de méthodes supervisées (chapitre 4) et de méthodes automatiques (chapitre 5). Pour ces premières, nous nous sommes restreints aux méthodes bayésiennes; pour les secondes, nous avons choisi les exemples des k-moyennes et des c-moyennes floues.

Dans cette partie, nous laissons de côté toute information contextuelle (les parties III et IV leur seront destinées). Nous considérons donc que l'information portée par un voxel est limitée à sa radiométrie; nous verrons alors jusqu'où nous mènent les procédures de classification non contextuelle.

Certaines conclusions de cette partie influencent directement la constitution de la procédure originale de reconnaissance que nous proposons en partie IV.

# **Chapitre 3**

# Classifier et/ou reconnaître

Le but de ce court chapitre introductif est de montrer, à la lumière du chapitre 2 sur l'observation en IRM 3D, comment nous pouvons appliquer des classifications à des fins de segmentation, et d'expliquer à quel point nous pouvons parler de reconnaissance.

# 3.1 Qu'est-ce que classifier en IRM?

## 3.1.1 Contexte général

La classification est la dernière des trois étapes du schéma classique de reconnaissance des formes décrit ci-dessous; nous nous restreignons ici aux informations numériques et écartons le cas où des informations symboliques sont à prendre en compte.

1. Acquisition des données :

on réalise des mesures sur l'ensemble des individus d'une population; pour chaque individu, on obtient donc un vecteur de données numériques.

2. Extraction des caractéristiques :

on effectue des transformations sur l'espace des données pour les rendre plus pertinentes (généralement moins redondantes et/ou plus discriminantes); le vecteur de données de chaque individu devient vecteur des caractéristiques de l'individu.

3. Mise en œuvre d'un classifieur :

les caractéristiques d'un individu témoignent de son appartenance à une classe, c'est-à-dire, un ensemble d'individus; un classifieur est un procédé à même d'attribuer une classe à un individu au regard de ses caractéristiques.

Une classe de la population est une catégorie relativement homogène d'individus et relativement distincte des autres catégories.

## 3.1.2 Application à l'IRM 3D

En IRM 3D, l'individu de plus bas niveau est le voxel, et la population, l'ensemble des voxels formant une image, constituée d'une acquisition simple ou de plusieurs acquisitions (nous supposons

pour cette étape que les différentes acquisitions sont recalées). Chaque voxel a pour données, d'une part son site dans l'image, et d'autre part son vecteur de mesure(s) radiométrique(s). Ce vecteur radiométrique a pour dimension le nombre d'acquisitions; une composante de ce vecteur n'est autre que le niveau de gris du voxel dans l'acquisition correspondante.

Pour l'étape 2 d'extraction des caractéristiques, nous identifions simplement les vecteurs des caractéristiques aux vecteurs des données. Cette pratique est générale bien que certains auteurs préconisent l'emploi de techniques d'analyse en composantes principales afin d'obtenir des caractéristiques de classe moins bruitées et mieux séparables [SOLT-96].

Un voxel a pour caractéristiques ses coordonnées spatiales dans l'image, et son vecteur radiométrique, constitué de l'ensemble des radiométries de ce voxel dans les acquisitions.

Si les informations de radiométrie étaient les seules prises en compte, classifier reviendrait à affecter une classe à chaque valeur radiométrique. L'assertion « chaque individu appartient à une classe » pourrait alors se traduire par « à chaque valeur radiométrique correspond une structure ». Or, comme nous l'avons vu dans la partie précédente, ce n'est pas suffisant puisque deux structures distinctes peuvent donner une même radiométrie.

Nous ne pouvons pas non plus traduire « chaque individu appartient à une classe » par « chaque voxel appartient à une structure » puisque, comme nous l'avons observé, les voxels de mélange sont constitués de plusieurs structures.

Une question que nous pouvons nous poser pour chaque voxel de mélange est de savoir quelle est la structure la plus représentée dans le mélange. La généralisation aux voxels purs est naturelle; classifier un voxel peut donc signifier « trouver la structure majoritaire au sein de ce voxel ».

## 3.2 Qu'est-ce que reconnaître en IRM?

## 3.2.1 Définition

Déterminer les classes au sein d'une population a plusieurs significations.

L'identité des classes, et *a fortiori* leur nombre, peuvent être inconnus. La classification a alors pour but d'exhiber dans une population des catégories dont même l'expert n'a pas idée *a priori* et la sémantique de ces catégories n'apparaît alors qu'à l'issue d'une étape d'analyse. Classifier revient à « prendre connaissance ».

En revanche, lorsque la sémantique des classes est connue, la classification doit identifier l'appartenance de chaque individu à une classe donnée; on parle alors de « reconnaissance ». C'est ce dernier type de classification qui nous intéresse, les classes correspondant à diverses structures anatomiques connues et identifiables.

### 3.2.2 Problématique

#### Caractériser une classe

Si la sémantique d'une classe est connue, sa caractérisation au sein d'une population donnée peut être indéterminée. Classifier commence alors par une étape d'apprentissage des caractéristiques de chaque classe.

En imagerie par résonance magnétique, nous nous trouvons exactement dans le cadre de cette problématique : les paramètres d'acquisition réglés en clinique conditionnent la radiométrie des structures cérébrales dans l'IRM, leurs caractéristiques radiométriques doivent donc être déterminées.
### Nombre de classes

Si nous nous restreignons, pour les besoins du problème, à une partie de la population, nous sommes confrontés à un problème nouveau : la présence effective d'une classe dans la population observée peut ne pas être garantie et le nombre de classes à caractériser devient alors une inconnue supplémentaire.

En IRM, nous nous heurtons à cette difficulté lorsque nous essayons de classifier des régions d'intérêt dont la localisation dans le cerveau est approximative. Ce cas de figure survient au cours de la procédure de reconnaissance que nous proposons en partie IV.

Lorsque le sujet est susceptible de présenter une pathologie, nous sommes de nouveau confrontés au problème du nombre inconnu de classes.

#### 3.2.3 Apprentissage

L'apprentissage peut être supervisé ou non [DUDA-73].

Dans le premier cas, un expert détermine la classe d'un certain nombre d'individus puis l'étude de cet ensemble permet d'obtenir les caractéristiques de la classe en question. C'est l'approche que nous avons menée pour vérifier la gaussienneté des lois radiométriques des structures (Cf. section 2.3.2). Le classifieur peut alors reconnaître la classe de tout individu en comparant ses caractéristiques propres à celles des différentes classes. Ce premier cas fait l'objet du chapitre 4 suivant.

Le chapitre 5 traite du second cas. L'apprentissage est algorithmique et l'on parle de classification automatique; les phases d'apprentissage et de reconnaissance sont alors souvent confondues ou menées simultanément.

## 3.2.4 Validation

Considérons une sémantique clairement définie pour chaque classe ; nous appellerons classification « effective » la classification recherchée qui satisfait au mieux cette sémantique. Ainsi, toute classification répondant à cette sémantique pourra lui être comparée ; en particulier, un individu sera dit bien classifié si la classe qui lui est attribuée est sa classe effective. Notons qu'il est difficile de comparer deux classifications de sémantiques différentes.

Une façon d'estimer la validité d'une reconnaissance consiste à calculer pour chaque classe son taux de reconnaissance (nombre d'individus affectés à juste titre à cette classe sur le nombre total d'individus de la classe effective correspondante) et son taux de fausses alarmes (nombre d'individus affectés par erreur à cette classe sur le nombre total d'individus affectés à cette classe).

Pour ce faire, il faut disposer d'une segmentation effective qui sert de référence ; dessinée par un expert humain, elle est malheureusement subjective. En l'absence d'une telle référence « idéale », la qualité d'une reconnaissance ne peut être quantifiée de cette façon.

Propres à la notion de classification, de nombreux critères de validité ont été définis [DUBU-90]. Leur expression se calcule dans l'espace des caractéristiques et fait intervenir une fonctionnelle; lorsque la méthode de classification a pour but de minimiser une fonctionnelle, la fonctionnelle de validité est choisie de façon à lui être indépendante.

Au vu des résultats que nous obtenons dans cette thèse, une estimation visuelle de leur qualité est suffisante pour pouvoir les comparer. Nous nous limitons volontairement à cette approche, les critères classiques de validité en classification ne prenant pas en compte l'aspect contextuel des individus dans l'image.

# 3.3 Conclusion

Pour tout individu voxel, nous souhaitons déterminer quelle est la structure majoritaire au sein de ce voxel. Mettre en œuvre une classification qui s'appuie sur les informations radiométriques devrait nous permettre de mettre en évidence les trois matières cérébrales :

- le liquide céphalo-rachidien,
- la substance grise,
- la substance blanche.

Pour les méthodes bayésiennes, l'apprentissage des caractéristiques des classes est supervisé (chapitre 4); nous pouvons donc essayer de discriminer au sein de la substance grise plusieurs classes correspondant au cortex et aux noyaux de la base.

Pour les méthodes automatiques, l'apprentissage est non supervisé (chapitre 5). Comme nous allons classifier tous les voxels des acquisitions IRM, nous pouvons nous attendre à devoir considérer plus de classes afin de prendre en compte des populations de voxels extra-cérébraux qui correspondent à l'air, l'os, la graisse, la peau, le muscle, etc. Le nombre de classes n'est donc pas fixé *a priori*.

# **Chapitre 4**

# Méthodes supervisées

Les méthodes supervisées comportent deux étapes : la première a pour but d'apprendre les caractéristiques de chaque classe (la section 2.3 propose à cet effet un protocole original et robuste), et la seconde, de décider de l'appartenance d'un individu à telle ou telle classe.

L'application des méthodes statistiques à la reconnaissance des formes a été formalisée par Chow en 1965 [CHOW-65]. Depuis, de nombreux systèmes de reconnaissance s'inspirent de ces méthodes. Dans ce domaine très vaste, notre choix s'est porté vers la théorie bayésienne de la décision, approche statistique bâtie sur l'hypothèse que le problème d'affectation d'un individu à une classe est posé en termes probabilistes (probabilités conditionnelles *a priori* et *a posteriori*).

Après examen du vecteur de caractéristiques d'un individu, la décision de l'affectation de cet individu à une classe bien particulière est rarement évidente. En effet, la variabilité entre ses caractéristiques et celles de la classe à laquelle il appartient effectivement interdit toute certitude. L'utilisation des probabilités est alors justifiée.

Notre but n'est pas ici d'étudier l'étendue des méthodes probabilistes mais de comprendre quels peuvent être leurs intérêts pour le problème qui nous occupe et quelles sont leurs limitations. Nous avons donc choisi de nous intéresser plus particulièrement aux méthodes bayésiennes; faciles à mettre en œuvre, elles bénéficient d'un large succès dans la communauté de la reconnaissance des formes et de la classification.

Nous rappelons brièvement les notions essentielles de la théorie bayésienne de la décision (section 4.1) et la façon dont nous allons l'appliquer en IRM 3D (section 4.2). Nous examinons alors les méthodes bayésiennes paramétriques et présentons des résultats (section 4.3); enfin, nous citons pour mémoire les méthodes bayésiennes non paramétriques (section 4.4).

Le tableau 4.1 indique les notations employées par la suite. Remarquons que les caractéristiques des individus s'expriment généralement sous forme numérique et sont alors presque toujours quantifiées et bornées ; ainsi E, l'espace des caractéristiques, est souvent de support discret et borné.

# 4.1 Théorie bayésienne de la décision

# 4.1.1 Théorème de Bayes

Afin de modéliser une population de façon statistique, on va considérer x non plus comme un vecteur de l'espace E des caractéristiques mais comme une variable aléatoire continue dont la distri-

notation	signification	propriétés
E	espace des caractéristiques	
p	le nombre de caractéristiques	$E \subset \mathbf{R}^p$
x	un vecteur de caractéristiques	$x \in E$
X	ensemble des individus à classifier	$X \subset E$
n	nombre d'individus à classifier	$n = \operatorname{card}(X)$
$x_k$	un individu à classifier	$x_k \in X$
Ω	ensemble des classes	
c	nombre de classes	$c = \operatorname{card}(\Omega)$
$\omega_i$	la classe <i>i</i>	$\omega_i\in\Omega$
		$\omega_i \cap \omega_j = \emptyset \iff i \neq j$
		$\bigcup_{i=1}^{c} \omega_i = E$
$\omega(x)$	classe attribuée à x	$\omega(x)\in\Omega$
$\Omega_E$	ensemble des classes effectives	
$\omega_x$	classe effective de x	$\omega_x\in\Omega_E$
$n_i$	nombre d'individus de X dans $\omega_i$	$n_i = \operatorname{card}(X \cap \omega_i)$
		$= \operatorname{card} \{ x_k, \ \omega(x_k) = \omega_i \}$
		$n = \sum_{i=1}^{c} n_i$
$A_i$	ensemble d'apprentissage pour $\omega_i$	$A_i \subset E$
$x_k^{A_i}$	un vecteur d'apprentissage pour $\omega_i$	$x_k^{A_i} \in A_i$
$n_{A_i}$	nombre de vecteurs d'apprentissage pour la classe $i$	$n_{A_i} = \operatorname{card}(A_i)$

TAB. 4.1 – Notations pour la classification

bution dépend de l'état effectif des données. Les classes seront supposées disjointes deux à deux et formant un ensemble exhaustif sur E.

- La fonction densité de probabilité jointe entre x et  $\omega_i$  qui traduit la probabilité élémentaire de trouver un individu de vecteur de caractéristiques x et de classe  $\omega_i$  est notée :

$$p: \left\{ \begin{array}{ccc} (E \times \Omega) & \Leftrightarrow & [0,1] \\ (x,\omega_i) & \Leftrightarrow & p(x,\omega_i) \end{array} \right.$$

Par la suite, nous réutilisons l'écriture p pour désigner d'autres fonctions de densités de probabilité que celle-là; du fait de la différence des paramètres de ces fonctions, toute ambiguïté est levée implicitement.

- La probabilité de trouver dans E un individu ayant comme caractéristiques x a pour densité :

$$p(x) = \sum_{i=1}^{n} p(x, \omega_i).$$

- La probabilité de trouver un individu de classe  $\omega_i$  parmi des individus de caractéristiques x (probabilité conditionnelle de  $\omega_i$  sachant x) a pour densité :

$$p(\omega_i|x) = \frac{p(\omega_i, x)}{p(x)}.$$

Comme elle traduit la probabilité de décision pour la classe  $\omega_i$  à partir d'une observation, on l'appelle densité de probabilité *a posteriori*.

- Par opposition, la probabilité *a priori* de décision pour la classe  $\omega_i$ , ou probabilité de trouver dans *E* un individu de classe  $\omega_i$ , s'écrit :

$$P(\omega_i) = \int_{x \in E} p(x, \omega_i) \, dx$$

- La probabilité de trouver un individu de caractéristiques x parmi les individus de la classe  $\omega_i$  (probabilité conditionnelle de x sachant  $\omega_i$ ) a pour densité :

$$p(x|\omega_i) = \frac{p(x,\omega_i)}{P(\omega_i)}$$

Par combinaison, on aboutit au théorème de Bayes :

$$p(\omega_i|x) = \frac{p(x|\omega_i) P(\omega_i)}{p(x)},$$

où l'observation de x change la probabilité a priori  $P(\omega_i)$  en densité de probabilité a posteriori  $p(\omega_i|x)$ . L'intérêt de cette formulation réside dans le fait que la probabilité a priori et la densité de probabilité conditionnelle  $p(x|\omega_i)$  sont deux quantités plus facilement mesurables que la densité de probabilité a posteriori.

### 4.1.2 Fonction de décision bayésienne

La fonction de décision bayésienne c associe à chaque individu la classe à laquelle il appartient avec la probabilité la plus importante ; c'est la règle du maximum *a posteriori* (MAP) ; elle s'écrit :

$$c: \begin{cases} E \iff \Omega\\ x \iff \omega_i, \ p(\omega_i|x) \ge p(\omega_j|x) \ \forall j = 1..n. \end{cases}$$

On montre que la fonction de décision bayésienne minimise la probabilité globale d'erreur :

$$err(c) = \int_{x \in E} \operatorname{proba}(c(x) \neq c_0(x)) p(x) \, dx,$$

avec  $c_0$  la fonction de décision idéale ( $c_0(x) = \omega_x \ \forall x \in E$ ).

Pour classifier avec un minimum d'erreur, on doit donc connaître la densité de probabilité *a posteriori*. Or grâce au théorème de Bayes, la décision s'écrit encore :

$$c(x) = \omega_i, \quad p(x|\omega_i)P(\omega_i) \ge p(x|\omega_j)P(\omega_j) \quad \forall j = 1..n,$$
(4.1)

utilisant ainsi les probabilités *a priori* et les densités de probabilité d'une observation sachant une classe, estimables après apprentissage.

## 4.1.3 Introduction éventuelle d'un coût

Pour des problèmes bien particuliers, certaines décisions peuvent porter plus à conséquences que d'autres ; par exemple, pour la classe d'une pathologie, on souhaite généralement obtenir le meilleur taux de reconnaissance possible même au prix d'un fort taux de fausses alarmes. En effet, décider d'affecter un voxel à une classe non pathologique augmente le risque de ne pas avoir détecté de

maladie; en revanche, affecter ce voxel à la classe pathologie peut être une erreur mais comporte moins de risque clinique<sup>1</sup>.

Pour tenir compte de cette notion de risque, on introduit généralement un coût affectant chaque classe. Dans le cadre de notre travail de recherche, nous ne traitons pas les cas de cerveaux pathologiques; nous ne tenons donc aucun compte de cette notion de risque et ne faisons jamais intervenir de coût.

# 4.2 Application bayésienne en IRM 3D

# 4.2.1 Problématique

Dans le cadre des images IRM 3D de la tête, l'apprentissage revêt une importance particulière. Il s'avère, en effet, que le recouvrement radiométrique des classes est très important; trois problèmes surviennent.

Le premier concerne les classes pour lesquelles aucun apprentissage n'a eu lieu. On ne peut pas demander au praticien d'effectuer l'étape d'apprentissage pour l'ensemble des structures présentes dans l'image ; ce travail serait trop laborieux. De telles classes sont donc légion ; citons pour exemple la région extra-cérébrale : les yeux, la graisse, la peau, le crâne, l'air, et pour le cerveau-même : les vaisseaux sanguins, les noyaux gris de petite taille, le claustrum, etc.

En conséquence, les voxels de l'image appartenant à de telles structures « oubliées » seront classifiés à tort parmi les classes apprises, ce qui peut conduire à des erreurs lorsqu'un algorithme devra se charger de la reconnaissance des classes.

Le deuxième problème correspond à un litige entre deux classes de radiométries voisines. Prendre en compte ces deux classes signifie, à cause de l'étalement de la radiométrie de chacune (dû en partie au bruit et aux paramètres d'acquisition), affecter à une classe une part importante des individus de l'autre classe, et réciproquement.

Il est alors conseillé d'abandonner une des deux classes au profit de l'autre puis d'effectuer la distinction entre les deux structures correspondantes à l'aide d'un autre moyen, leur localisation spatiale par exemple.

Le troisième problème est lié à la présence de volumes partiels. Si deux classes de radiométries distinctes correspondent à des structures voisines dans l'image, et si une troisième classe possède une radiométrie intermédiaire, alors les voxels situés à la frontière entre les deux structures seront affectés à la troisième classe.

Nous pourrions envisager de résoudre ce problème, soit en estimant le contenu des volumes partiels, soit en atténuant l'effet de volume partiel, mais nous préférons pour l'instant laisser à des post-traitements le soin de régler ce problème de mauvaise classification.

Les résultats obtenus dans les sections suivantes vont nous permettre d'illustrer les trois problèmes dont nous venons de discuter.

## 4.2.2 Classe de rejet

Sachant que nous ne cherchons à classifier que certains objets présents dans les images cérébrales, l'emploi d'une classe de rejet semble pertinent.

Une fois que l'apprentissage est mené, un certain nombre de voxels de l'image peuvent avoir des caractéristiques qui ne permettent pas de les classifier; ils seront donc rejetés.

<sup>1.</sup> cette erreur ne conduit pas systématiquement le patient à suivre une thérapie lourde

La caractéristique radiométrique d'une classe de rejet, résultante de ces voxels, n'a pas de sens à proprement parler puisqu'elle est issue d'un agrégat de voxels qui n'est significatif d'aucune classe en particulier; la classe de rejet contient généralement des voxels de plusieurs structures. En revanche, elle tient compte de chaque individu que l'utilisateur n'a pas cru bon d'apprendre; en cela elle témoigne de l'ensemble des individus dont la classification peut être hasardeuse.

Cette non-caractéristique de classe peut nous servir à l'établissement de la classe de rejet en participant à la classification au même titre que les caractéristiques apprises. Une telle classe comporte d'après [DUBU-90]:

- les voxels de rejet en ambiguïté, individus hésitant entre plusieurs classes (c'est-à-dire qui ne peuvent être affectés de manière suffisamment significative dans une classe au regard d'une ou plusieurs autres classes),
- les voxels de rejet en distance, individus se démarquant de toute classe (c'est-à-dire de caractéristiques éloignées de celles des classes connues donc appartenant peut-être à une classe non prévue).

Cette idée sera exploitée dans les sections suivantes. Notons qu'elle ne résout en rien les problèmes précédemment exposés mais qu'elle nous apporte des informations supplémentaires nécessaires à une classification ultérieure plus robuste.

## 4.2.3 Images utilisées

Dans la suite de ce chapitre, afin de tester les méthodes bayésiennes, nous utiliserons d'une part l'image  $xavT_1$ , acquisition en  $T_1$  (l'histogramme de cette image est donné en figure 2.7 page 42), et d'autre part l'image constituée des deux acquisitions  $xavT_1$  et  $xavT_{2a}$ , respectivement en  $T_1$  et  $T_2$ , et dont l'histogramme est porté en figure 4.1.

Dans la partie I, la figure 2.6 présente une coupe des acquisitions de l'image x av.

# 4.3 Méthodes bayésiennes paramétriques

Les méthodes paramétriques bayésiennes consistent à modéliser chacune des fonctions  $p(x|\omega_i)$  et à se contenter d'estimer les paramètres de ce modèle. Notons  $\theta_i$  le vecteur des M paramètres du modèle en question :

$$\theta_i = (\theta_i^{(1)}, \dots, \theta_i^{(M)}).$$

Les densités s'écrivent maintenant  $p_{\theta_i}(x|\omega_i)$ , et il s'agit alors, pour chaque classe  $\omega_i$ , d'estimer le meilleur paramètre  $\theta_i$  connaissant l'ensemble d'apprentissage  $A_i$ .

# 4.3.1 Estimateur du maximum de vraisemblance

De nombreux estimateurs statistiques sont disponibles mais le plus fréquemment utilisé est l'estimateur du maximum de vraisemblance. Supposons que nous connaissions  $\theta_i$ . La densité de probabilité traduisant le fait que l'individu  $x_j$  fasse partie de l'ensemble d'apprentissage  $A_i$  est  $p_{\theta_i}(x_j|\omega_i)$ et la probabilité (ou représentativité) de l'ensemble d'apprentissage  $A_i$  s'écrit :

$$P_i(\theta_i) = \prod_{x_j \in A_i} p_{\theta_i}(x_j | \omega_i),$$



FIG. 4.1 – Histogramme 2D de l'image bi-acquisitions ( $xavT_1$ ;  $xavT_{2a}$ )

Le nombre d'occurrences d'un vecteur radiométrique se traduit par un niveau de gris, de plus en plus foncé lorsque le nombre d'occurrences augmente. Pour mieux apprécier la forme de l'histogramme (et de ses faibles valeurs), les niveaux de gris de cette figure sont en fait proportionnels au logarithme du nombre d'occurrences de chaque vecteur radiométrique dans l'image. Les matières importantes sont localisées approximativement dans cet histogramme par leur symbole respectif.

en supposant les échantillons  $x_j$  indépendants.

L'estimateur du maximum de vraisemblance propose de choisir, parmi toutes les fonctions densités, celle pour laquelle on aurait eu la plus forte probabilité de tirer l'ensemble d'apprentissage proposé. Cela se traduit par le choix du vecteur de paramètres  $\theta_i$  qui maximise la probabilité  $P_i$ , soit  $\theta_i$  qui annule les dérivées partielles de  $P_i$ :

$$\frac{\partial \sum_{x_j \in A_i} \log p_{\theta_i}(x_j | \omega_i)}{\partial \theta_i^{(m)}}(\theta_i) = 0 \quad \forall m = 1..M$$
(4.2)

## 4.3.2 Cas gaussien en dimension 1

Dans le cadre d'une acquisition unique, la règle de décision bayésienne appliquée à la radiométrie des voxels revient à affecter une classe à un individu suivant sa mesure radiométrique. Classifier revient alors à seuiller l'histogramme.

Si les lois des densités sont gaussiennes et de dimension 1, le vecteur de paramètres à estimer pour chaque classe est  $\theta_i = (v_i, \sigma_i)$ ; on a :

$$p_{\theta_i}(x|\omega_i) = \frac{1}{\sqrt{2\pi}\,\sigma_i} \exp\left[ \Leftrightarrow \frac{1}{2} \left( \frac{|x \Leftrightarrow v_i|^2}{\sigma_i^2} \right) \right].$$

En appliquant l'équation (4.2), on trouve que la loi gaussienne qui maximise la vraisemblance n'est autre que la gaussienne qui a même moyenne et même variance que  $A_i$ . La règle de décision bayésienne 4.1 nous fournit alors le classifieur  $w(x) = \omega_i$  avec *i* minimisant:

$$\frac{|x \Leftrightarrow v_i|^2}{\sigma_i^2} + 2\left[\log \sigma_i \Leftrightarrow \log P(\omega_i)\right],\tag{4.3}$$

où | . | est la norme euclidienne. Si les  $P(\omega_i)$  étaient tous égaux et s'il en était de même pour les variances, x appartiendrait à la classe de plus proche centre (on parle de classifieur à moindre distance); ce n'est bien entendu pas le cas de nos classes en IRM. Nous reparlerons de cette règle de décision dans le cadre des classifications markoviennes en section 6.2.4.

Considérons, sur la figure 4.2, six des ensembles d'apprentissage issus de notre protocole; leurs caractéristiques radiométriques ont fait l'objet du tableau 2.5.



FIG. 4.2 – Histogramme 1D des ensembles d'apprentissage de  $xavT_1$ 

On observe sur cette figure le fort recouvrement radiométrique de six des ensembles d'apprentissage dessinés dans  $xavT_1$  avec le protocole décrit dans la section 2.3 de la partie I : LCR liquide céphalo-rachidien, HVT humeur vitrée de l'œil, MUS muscle, NCA noyau caudé, PUT putamen, SBL substance blanche.

Les moyennes radiométriques des objets yeux et liquide céphalo-rachidien sont trop proches l'une de l'autre (deuxième problème soulevé en section 4.2.1) pour espérer que la classification les distingue correctement; il en est de même pour les objets caudate et putamen, lesquels ont des radiométries proches de celle de l'objet muscle.

Il est donc dans notre intérêt de considérer, d'une part, une classe liquide qui contient les yeux et le LCR, et d'autre part, une classe substance grise qui contient sans discernement non seulement caudate et putamen (ainsi que les autres noyaux gris et le cortex) mais aussi tout ce qui est muscle. Dans le premier cas, ce problème n'est pas gênant car un post-traitement morphologique peut nous permettre d'isoler les yeux; il en est de même pour l'identification des muscles dans le second cas. En revanche, comme nous le verrons par la suite, effectuer une reconnaissance des différents noyaux n'est pas aisé.

Nous nous plaçons ici dans la cadre de l'hypothèse du caractère gaussien de la distribution radiométrique des objets en IRM, hypothèse que nous avons justifiée au cours de la partie I. La théorie bayésienne nous permet donc d'affirmer que les densités de probabilité d'une observation sachant une classe suivent une loi gaussienne de mêmes caractéristiques que l'ensemble d'apprentissage de cette classe.

Les probabilités *a priori* d'une classe peuvent être déduites de la cardinalité des ensembles d'apprentissage suivant :

$$P(\omega_i) = \frac{n_{A_i}}{\sum_{j=1}^c n_{A_j}}.$$

Cela suppose toutefois que le dessin des régions d'apprentissage dans l'image soit significatif de leur représentativité, ce qui est loin d'être évident. On préférera donc plutôt se fier à la connaissance *a priori* du volume des différentes structures cérébrales.

Les figures 4.3 et 4.4 regroupent les résultats obtenus.

Sur la figure 4.3, nous observons à l'œil que les différences de segmentation suivant que le second terme du classifieur (donné en formule (4.3)) est présent ou non ne sont pas fondamentales ; toutefois les voxels changeant de classe à cette occasion représentent 8, 8% des voxels de l'image, ce qui est loin d'être négligeable.

L'image (a) de la figure 4.4 montre que la séparation par seuillage bayésien entre les deux structures de substance grise, noyau caudé et putamen, n'est pas exploitable; le recouvrement radiométrique entre ces deux structures est trop prononcé.

L'image (b) prend en compte l'humeur vitrée (liquide de l'œil) de caractéristiques radiométriques proches de celles du liquide céphalo-rachidien. Cette fois-ci la décision bayésienne est extrême puisque la classe liquide céphalo-rachidien disparaît; la majorité des voxels concernés sont étiquetés humeur vitrée.

L'image (c) fait intervenir la classe muscle qui perturbe la classification de la substance grise; une correction ultérieure de la segmentation résultante ne semble guère facile.

## 4.3.3 Cas gaussien en dimension 2 ou plus

#### Développement général

Pour des espaces de dimension d valant 2 ou plus, on admettra comme hypothèse que les lois de probabilité des différentes classes sont gaussiennes. Cette hypothèse a pour but de simplifier les calculs afin de mener à son terme la méthode bayésienne.

Les lois de vecteur centre et matrice de covariance  $(v_i, \Sigma_i)$  ont chacune un vecteur de  $d + \frac{d(d+1)}{2}$  paramètres à estimer :

$$\theta_i = (v_i^{(1)} .. v_i^{(p)}, \sigma_i^{(1,1)} .. \sigma_i^{(l,c)} .. \sigma_i^{(d,d)}) \quad \text{où} \quad 1 \le l \le c \le d.$$



Classifieur incomplet



Classifieur complet

FIG. 4.3 – Classifications bayésiennes en 1D

Ces images représentent une région de la coupe axiale  $n^{\circ}62$  de  $xavT_1$ . Elles sont issues de la classification bayésienne paramétrique prenant en compte les classes fond, liquide (liquide céphalo-rachidien et humeur vitrée des yeux), substance grise et substance blanche. L'image du haut résulte d'une utilisation restreinte au premier terme du classifieur donné en formule (4.3), contrairement à celle du bas qui l'utilise dans son intégralité et prend en compte les variances et probabilité *a priori* de chaque classe.



(a) NCA contre PUT



(b) HVT contre LCR



(c) MUS contre SGR

FIG. 4.4 – Mauvaises classifications bayésiennes en 1D

Les trois images de cette figure proviennent de classification bayésienne où la distinction entre deux classes de radiométrie voisine a été effectuée ; des anomalies en résultent. En appliquant l'équation (4.2), on trouve de nouveau que les centres des lois sont les centres des ensembles d'apprentissage correspondants. Quant aux variances, elles vérifient après élimination du biais :

$$\Sigma_i = \frac{1}{\operatorname{card}(A_i) \Leftrightarrow 1} \sum_{x_j \in A_i} (x_j \Leftrightarrow v_i) (x_j \Leftrightarrow v_i)^t.$$

Classifier revient à choisir i qui maximise :

$$p_{\theta_i}(\omega_i|x) = \frac{\exp\left[\Leftrightarrow_2^1 (x \Leftrightarrow v_i)^t \Sigma_i^{-1}(x \Leftrightarrow v_i)\right] P(\omega_i)}{2\pi^{\frac{1}{p}} \sqrt{\det \Sigma_i} p(x)},$$

ou de manière équivalente, à choisir i qui minimise :

$$q_i(x) = (x \Leftrightarrow v_i)^t \Sigma_i^{-1}(x \Leftrightarrow v_i) + [log(\det \Sigma_i) \Leftrightarrow 2\log P(\omega_i)].$$
(4.4)

Le premier terme de l'équation (4.4) s'interprète comme le carré d'une distance de x au centre  $m_i$  de l'ensemble d'apprentissage  $A_i$ . Cette distance, définie par la forme bilinéaire quadratique positive liée à la matrice  $\Sigma_i^{-1}$ , s'appelle la distance de Mahalanobis induite par  $A_i$ , sa boule unité (encore appelée ellipsoïde d'inertie) vérifiant :

$$(x \Leftrightarrow v_i)^t \Sigma_i^{-1} (x \Leftrightarrow v_i) = 1.$$

Quant au second terme, il est indépendant de x. C'est un terme correctif pouvant varier d'une classe à l'autre, parfois omis car souvent négligeable (la figure 4.3 montre que le cas mono-dimensionnel obéit effectivement à cette règle).

Enfin, les surfaces séparatrices entre régions antagonistes de l'espace de décision sont des hyperquadriques [DUDA-73].

#### Caractéristiques indépendantes et de même variance

Le cas le plus simple est celui où les caractéristiques des individus sont statistiquement indépendantes (matrice de covariance diagonale) et où elles ont toutes même variance (coefficients diagonaux égaux à la variance unique). Les classes suivent alors un modèle unique, celui d'une loi normale isotrope de variance fixe mais de centre variable. L'aspect de la population est donc un ensemble d'hypersphères centrées en différents points de l'espace, et les surfaces séparatrices sont des hyperplans.

Avec | . |, norme euclidienne, la quantité à minimiser devient :

$$\frac{|x \Leftrightarrow v_i|^2}{\sigma^2} \Leftrightarrow 2\log P(\omega_i)$$

Si de plus, les probabilités *a priori*  $P(\omega_i)$  ne diffèrent pas d'une classe à une autre, la quantité à minimiser se résume à la distance euclidienne au centre des classes. Un individu de vecteur de caractéristiques *x* appartient alors, comme dans le cas gaussien mono-dimensionnel, à la classe dont le centre est le plus proche.

#### Caractéristiques de même matrice de covariance

On suppose que  $\Sigma_i = \Sigma$  pour tout *i*. Par une transformation linéaire sur l'espace, on se ramène au cas précédent. Les classes ressemblent donc à des hyperellipsoïdes de même taille et de même

aspect mais centrés en différents points de l'espace ; dans ce nouvel espace, les surfaces séparatrices sont encore des hyperplans. La partie  $log (det \Sigma_i)$  du terme correctif n'entre plus en compte et la distance de Mahalanobis est la même pour toutes les classes.

Si les classes sont équiprobables, on est en présence d'un classifieur à moindre distance de Mahalanobis.

#### Résultats

Les classifications bayésiennes que nous avons menées utilisent uniquement le premier terme du classifieur de la formule (4.4), les changements induits par la présence du second terme étant sans conséquences fondamentales sur les résultats obtenus.

La figure 4.5 présente les régions de l'espace 2D de décision issues d'un classifieur paramétrique bayésien appliqué à l'image  $(x av T_1, x av T_{2a})$ . La forme de ces régions varie avec la prise en compte ou la non-prise en compte de certaines classes; le résultat des classifications correspondantes est illustré par la figure 4.6.

Les quatre cas envisagés possèdent tous les classes air, liquide céphalo-rachidien et substance blanche. Leurs spécificités respectives sont les suivantes.

Le cas (a) distingue noyau caudé et putamen tandis que les trois autres ne considèrent qu'une classe substance grise unique. Par rapport au cas (d), cela se traduit par la séparation en deux parties de la région de décision substance grise et une légère modification de la frontière des autres régions.

Tout comme nous l'avions déjà constaté lors de la classification monodimensionnelle, la différentiation des différentes structures grises est impossible à cause de leur fort recouvrement radiométrique. De plus, la classe putamen est présente dans le volume partiel entre le cortex (de même radiométrie que le noyau caudé) et la substance blanche.

Les cas (b) et (c) prennent en compte chacun une classe supplémentaire, respectivement, humeur vitrée de l'œil et muscle.

Le dessin des régions (b) illustre le fait que les radiométries du liquide céphalo-rachidien et de l'humeur sont encore proches (d'où la forme bizarre des frontières); la prise en compte de l'acquisition en  $T_2$  n'a pas amélioré la situation déjà observée en mono-dimensionnel: la segmentation résultante est mauvaise.

La séparation des caractéristiques des classes muscle et substance grise est maintenant effective grâce à une différence de radiométrie en  $T_2$ . Cependant, la classe muscle domine encore la classe substance grise et la nouvelle segmentation reste trop erronée.

Le cas (d) semble de loin le plus raisonnable avec ses quatre classes : air, liquide céphalorachidien, substance grise et substance blanche ; la segmentation qui en résulte est très correcte.

Enfin, la mise en place d'une classe de rejet restreint l'étendue des régions de décision et fournit une segmentation partielle; les voxels de rejet sont exclus de la segmentation. Nous décidons qu'un voxel n'est pas rejeté et est affecté à une classe lorsque ses caractéristiques correspondent fortement aux caractéristiques de cette classe.

Dans le cadre de la modélisation gaussienne des lois radiométriques, nous définissons de façon arbitraire que « fortement » signifie que les caractéristiques du voxel sont à l'intérieur de l'ellipsoïde d'inertie de sa classe. Dans le cas monodimensionnel, un voxel est affecté à une classe si la différence entre sa radiométrie et la radiométrie moyenne de cette classe reste inférieure à l'écart-type de la loi radiométrique de cette classe.

C'est donc un outil idéal pour connaître *a priori* les voxels de l'image dont l'affectation à une classe paraît sûre. La figure 4.7 illustre le résultat obtenu.



FIG. 4.5 – Régions de l'espace 2D de décision bayésienne

L'abscisse porte la radiométrie de l'acquisition  $xavT_1$  (faible à gauche, forte à droite) et l'ordonnée, celle de  $xavT_{2a}$  (faible en haut, forte en bas). Les classes prises en compte lors de la classification sont: (a) air, liquide céphalo-rachidien, noyau caudé, putamen, substance blanche; (b) air, liquide céphalo-rachidien, humeur vitrée de l'œil, substance grise, substance blanche; (c) air, liquide céphalo-rachidien, muscle, substance grise, substance blanche; (d) air, liquide céphalo-rachidien, substance grise, substance blanche; (d) air, liquide céphalo-rachidien, substance grise, substance blanche. Ces régions de décision sont à rapprocher de l'histogramme donné en figure 4.1.



(a) séparation de SGR en deux classes NCA et PUT



(b) ajout de la classe HVT proche de LCR



(c) ajout de la classe MUS proche de SGR



(d) classes AIR, LCR, SGR et SBL

FIG. 4.6 – Classifications bayésiennes bi-dimensionnelles

Cette figure illustre les classifications correspondant aux régions de décision de la figure 4.5. Les trois premières images de cette figure proviennent de classifications bayésiennes où la distinction entre deux classes de radiométrie voisine a été effectuée ; des anomalies en résultent. L'image du bas correspond à une classification où seules les quatre classes suivantes ont été apprises : air, liquide céphalo-rachidien, substance grise et substance blanche.



FIG. 4.7 – Classification bayésienne bi-dimensionnelle avec rejet

Cette figure est le pendant du cas (d) des figures 4.5 et 4.6 avec la présence supplémentaire d'une classe de rejet. L'image du haut représente les régions de décision ; en blanc, la région de rejet limite considérablement la taille des régions de décision des classes. L'image du bas montre la classification très partielle : seuls les voxels purs sont reconnus (en gris plus ou moins foncé).

# 4.4 Méthodes bayésiennes non paramétriques

Les méthodes bayésiennes non paramétriques supposent, contrairement aux méthodes paramétriques, que la forme des densités  $p(x|\omega_i)$  est quelconque et peut être approchée directement, sans utiliser de famille de fonctions. Nous citons ici pour mémoire ce type de méthodes que nous n'utilisons pas ; nous en rappelons seulement les principes de base.

#### 4.4.1 Principe général

La probabilité P qu'un vecteur x' de l'espace E tombe dans une région H de E s'exprime avec la densité de probabilité p dans la région H:

$$p(x' \in H) = \int_{H} p(x) \, dx.$$

Si la région H est suffisamment petite et si p est continue, une approximation de cette probabilité s'écrit :

$$P(x' \in H) \approx p(x) V(H), \tag{4.5}$$

avec x vecteur de H, et V(H) volume de H.

Une seconde approximation de cette probabilité s'obtient en considérant le nombre K de vecteurs tombant dans H lors d'un nombre important N de tirages indépendants dans E:

$$P(x' \in H) \approx \frac{K}{N}.$$
(4.6)

On obtient ainsi une estimation de la densité de probabilité p(x) en H de la forme :

$$p(x) \approx \frac{K}{N \times V(H)}$$

La pratique n'est pas aussi triviale. La région H doit être suffisamment petite pour que l'approximation locale (4.5) soit justifiée. D'un autre côté, si la région H est trop petite, le nombre de tirages la concernant sera trop faible et l'approximation (4.6) ne sera plus statistiquement fiable. Un compromis s'impose, en partie dicté par la taille des ensembles d'apprentissage.

Pour estimer la densité de probabilité en x, formons une suite de régions  $H_N$  contenant x, de volume  $V(H_N)$  et correspondant à N tirages dans E. Les estimations successives valent donc :

$$p_N(x) = \frac{K_N}{N \times V(H_N)}.$$
(4.7)

Pour que  $p_N$  converge vers p en x, trois conditions sont impératives :

$$\lim_{N \to +\infty} V(H_N) = 0$$
  
$$\lim_{N \to +\infty} K_N = +\infty$$
  
$$\lim_{N \to +\infty} \frac{K_N}{N} = 0$$

En pratique, ces contraintes sont trop fortes et elles ne peuvent donc pas être vérifiées. Toutefois, afin d'espérer des résultats corrects avec cette méthode, nous devrons nous assurer que la mise en œuvre respecte la tendance de ces trois limites.

#### 4.4.2 Fenêtres de Parzen

Les fenêtres de Parzen font partie des méthodes qui permettent de construire la suite de fonctions de densité de probabilité  $x \iff p_N(x)$ .

Considérons la fonction fenêtre centrée en 0 :

$$\phi(u) = \begin{cases} 1 & |u| \le \frac{1}{2} \\ 0 & \text{sinon.} \end{cases}$$

Prenons pour région  $H_N$  autour de x l'hypercube de côté de largeur  $h_N$  et centré en x; son volume est  $V(H_N) = h_N^p$ ; le nombre  $K_N$  de vecteurs  $x_l$  issus de N tirages dans E et tombant dans  $H_N$  s'exprime alors suivant:

$$K_N = \sum_{l=1}^N \phi\left(\frac{x \Leftrightarrow x_l}{h_N}\right).$$

En reportant cette expression dans (4.7), on obtient:

$$p_N(x) = \frac{\sum_{l=1}^N \phi\left(\frac{x - x_l}{h_N}\right)}{N \times h_N^p}$$

Dans un souci de généralité, nous ne nous restreindrons pas à une fonction fenêtre mais à une fonction densité vérifiant :

$$\phi(u) \ge 0 \quad \forall u \in E$$
$$\int_{u \in E} \phi(u) \, du = 1$$

Pour simplifier, posons  $N = n_{A_i}$  où  $x_l$  est un vecteur d'apprentissage de  $A_i$ . L'idée est simple : chaque vecteur d'apprentissage dans l'espace des caractéristiques augmente localement la densité de probabilité de la classe correspondante, et, lorsque tous les vecteurs d'apprentissage ont été pris en compte, la fonction densité de probabilité de chaque classe dans l'espace de décision est connue.

#### 4.4.3 Conditions de convergence

Sous des hypothèses peu contraignantes que nous allons rappeler, ces estimations convergent effectivement vers les densités lorsque le cardinal de l'ensemble d'apprentissage tend vers l'infini. Cette convergence, bien entendu probabiliste, est dite asymptotique.

La première hypothèse porte sur les densités à estimer qui doivent être continues, ce qui, dans la pratique, est généralement vérifié. Les autres hypothèses portant sur la forme des densités  $\phi_N$ , la méthode des fenêtres de Parzen ne souffre donc d'aucune restriction importante d'utilisation. Les  $\phi_N$  doivent être construites à partir d'une fonction « mère »  $\phi$  et d'une suite de réels positifs.

Une solution envisageable est de découper l'espace des mesures en pavés d'une certaine taille sur lesquels on pourra alors appliquer la règle de Bayes. Il ne faut pas toutefois tomber dans les deux excès suivants. Si le nombre de pavés est trop grand, les quantités  $p(x|\omega_i)$  et p(x) ne pourront pas être estimées avec précision. S'il est trop faible, le bruit de discrétisation risque d'introduire des erreurs du fait de l'hétérogénéïté au sein des pavés.

# 4.5 Conclusion

Les méthodes bayésiennes sont particulièrement bien adaptées à notre problème pour plusieurs raisons :

- les classes essentielles (liquide céphalo-rachidien, substance grise et substance blanche) ont généralement des radiométries bien distinctes,
- l'apprentissage de ces classes ne pose pas de difficulté car elles correspondent à des structures internes d'un volume important et facilement identifiables mais l'apprentissage est une procédure lourde en pratique,
- les probabilités a priori de ces classes sont connues,
- la classification par moindre distance de Mahalanobis est rapide et sa mise en œuvre est aisée.

Notre choix final se porte sur les méthodes paramétriques bayésiennes car, comme nous l'avons justifié, la radiométrie des structures internes est paramétrable par des lois gaussiennes (multi-dimensionnelles si les images sont multi-modales). Les résultats le confirment : nous obtenons une segmentation correcte du liquide céphalo-rachidien, de la substance grise et de la substance blanche comme le montre l'image (d) de la figure 4.6 78.

Cependant, nous avons montré qu'il est utopique d'espérer segmenter, à l'aide d'une classification supervisée non-contextuelle, les différentes structures constituées de substance grise; Cf. les images (a), (b) et (c) de la figure 4.6. En effet, pour que cela soit possible, il faudrait que les structures en question soient suffisamment distantes dans l'espace de décision pour que les recouvrements radiométriques entre elles soient faibles, ce qui est loin d'être garanti en utilisation clinique de l'IRM.

L'identification des différentes structures internes à l'issue de telles classifications est inexistante. Il nous faut donc envisager l'emploi d'informations contextuelles; ce sera le sujet de la prochaine partie (partie III).

# **Chapitre 5**

# Méthodes automatiques

Il n'est pas acceptable que, pour procéder à une segmentation bayésienne des structures internes du cerveau, le praticien doive dessiner les régions d'apprentissage correspondantes. Une telle tâche, fastidieuse, doit pourtant être répétée pour toute image car la majorité des appareils d'IRM normalisent les images et la radiométrie des structures varie d'une acquisition à une autre.

Il faut donc songer à se passer d'une étape d'apprentissage si l'on songe à mettre en œuvre dans les services radiologiques une procédure systématique de segmentation.

Nous allons tout d'abord nous intéresser à la méthode des k-moyennes (section 5.1); nous mettrons en évidence un certain nombre de problèmes qui n'ont pas été largement abordés dans la littérature et auxquels nous apportons des solutions (section 5.2). Nous nous penchons ensuite sur son adaptation floue, la méthode des c-moyennes, pour laquelle nous mettons en cause la forme des fonctions d'appartenance floue qu'elle produit (section 5.3). Enfin, nous présentons une méthode automatique d'obtention de telles fonctions (section 5.4), due à Isabelle Bloch, beaucoup mieux adaptées que les précédentes à une procédure ultérieure de fusion.

Nous nous sommes délibérément restreints à ces méthodes, en en laissant d'autres de côté (c'est le cas des méthodes non-supervisées paramétriques telles que les méthodes EM).

# 5.1 Méthode des k-moyennes

L'algorithme des k-moyennes, apparu dans [BALL-65], est un cas particulier d'une méthode de classification automatique beaucoup plus générale : les nuées dynamiques de Diday [DIDA-70].

# 5.1.1 Nuées dynamiques

La méthode des nuées dynamiques consiste à considérer que les classes formées d'individus ont un comportement de nuées groupées autour de noyaux.

Considérons sur E la mesure  $f(x, \omega_i)$  de dissimilarité (ou dissemblance) entre l'individu x et la classe  $\omega_i$ ; cette mesure, à valeurs dans  $\mathbb{R}^+$ , est calculée à partir du noyau de  $\omega_i$ . On se propose de classifier X de telle façon que la somme des mesures entre les individus et leur classe soit la plus faible possible. La fonction objectif à minimiser s'écrit alors :

$$g_f(\Omega) = \sum_{\omega_i \in \Omega} \sum_{x_k \in \omega_i} f(x_k, \omega_i)$$

Afin de minimiser la fonction objectif g, l'algorithme le plus fréquemment utilisé est le suivant :

- 1. it = 0
- 2. choisir une classification initiale de  $X : \{\omega_1^{(it)} .. \omega_c^{(it)}\}$
- 3. it = it + 1
- 4. actualiser chaque classe suivant:

$$\omega_i^{(it)} = \{ x_k \in X, \ f(x_k, \omega_i^{(it-1)}) \le f(x_k, \omega_j^{(it-1)}) \ \forall j \neq i \}$$

5. si  $\exists i, \ \omega_i^{(it)} \neq \omega_i^{(it-1)}$  alors retourner à l'étape 3

Lors d'une itération, on affecte à chaque individu la classe dont la caractérisation est la plus proche des caractéristiques de cet individu. Les classes ainsi redessinées voient leur forme évoluer progressivement et leurs caractéristiques changer dynamiquement.

A l'issue de la classification, les points de E à la frontière entre les classes d'indices respectifs i et j vérifient :

$$f(x,\omega_i) = f(x,\omega_j)$$

Dans la méthode des nuées dynamiques, les caractéristiques de chaque classe dépendent du noyau qui décrit cette classe; f est alors une fonction de dissimilarité entre un individu et le noyau d'une classe. Diday propose alors plusieurs exemples de mesure f, chacun garantissant la convergence de l'algorithme de descente exposé précédemment vers un minimum (local).

L'exemple le plus simple réduit le noyau d'une classe à un point de E, centre de gravité de la classe :

$$v_i = \frac{1}{\operatorname{card}\omega_i} \sum_{x_k \in \omega_i} x_k$$

La mesure peut se construire à l'aide d'une fonction distance d suivant  $f(x, \omega_i) = d(x, v_i)$ . Cette version des nuées dynamiques s'appelle méthode des k-moyennes.

Par extension, une classe  $\omega_i$  peut être représentée par un noyau constitué d'un ensemble de plusieurs points  $\{v_i^1 ... v_i^L\}$ . Une façon de les déterminer est de minimiser :

$$\sum_{x_k \in \omega_i} \inf_{l=1..L} d(x_k, v_i^l) \, .$$

La nouvelle mesure est alors par exemple :

$$f(x,\omega_i) = \frac{1}{L} \sum_{l=1..L} c_l d(x, v_i^l) ,$$

avec  $c_l$  le coût associé au lième point du noyau; ou encore :

$$f(x, \omega_i) = \frac{1}{L} \sum_{l=1..L} d^2(x, v_i^l)$$
.

La description par noyau réparti sur plusieurs points permet de mieux s'adapter à des classes de forme plus complexe. Un noyau constitué autour de l'axe principal d'inertie  $\Delta_i$  de la classe  $\omega_i$  pourrait donner comme mesure :

$$f(x,\omega_i) = \inf_{x' \in \Delta_i} d(x,x') .$$

# 5.1.2 Limitations

Trois remarques s'imposent.

Premièrement, cet algorithme fonctionne pour un nombre de classes donné; il ne résout donc pas la question du nombre de classes. Nous verrons ultérieurement les réponses qui peuvent y être apportées.

Deuxièmement, cet algorithme est malheureusement un algorithme de descente ; il converge donc vers un minimum local. Si l'on souhaite éviter l'écueil d'un minimum local trop éloigné de la solution optimale, il faut alors mettre en œuvre une stratégie de recherche globale.

Une première solution, empirique, consiste à exécuter plusieurs fois cet algorithme mais avec des classifications initiales différentes. Le résultat retenu est alors, soit celui qui minimise la valeur finale de la fonction objectif, soit, lorsque la fonction objectif n'est pas évaluée, celui qui revient le plus souvent et qui témoigne ainsi de la présence de classes stables.

Une seconde solution consiste à perturber régulièrement les classes [FRIE-67] grâce à des matrices de dispersion.

Enfin troisièmement, la mesure f choisie doit garantir la convergence de la méthode d'optimisation.

## 5.1.3 Mise en pratique des k-moyennes

#### Une distance comme dissimilarité

Les individus à classifier étant décrits par des vecteurs de l'espace des caractéristiques, on munit généralement ce dernier de distances métriques. En choisissant une métrique pour chacune des classes, la distance d'un individu  $x_k$  au centre  $v_i$  de la classe  $\omega_i$  s'écrit alors naturellement :

$$d(x,\omega_i) = d_i(x,v_i)$$

On utilise fréquemment une des trois distances suivantes :

$$d_i = L_1$$
  

$$d_i = L_2$$
  

$$d_i^2(x, y) = (x \Leftrightarrow y)^t M_i (x \Leftrightarrow y)$$

Lorsque k augmente, on constate empiriquement que la partition de E a tendance à donner aux classes des formes sphériques et des volumes comparables.

Avec la troisième distance, le choix de la matrice  $M_i$  conditionne l'aspect morphologique de la classe  $\omega_i$ , et influence par là-même la forme des autres classes :

- si  $M_i = I^p$  (matrice identité de dimension p), on retrouve la distance euclidienne  $L_2$ ,
- si  $M_i = \sum_i^{-1}$ , matrice de covariance centrée d'un ensemble  $A_i$ , on retrouve la distance de Mahalanobis qui tient compte de l'étendue, variable suivant les classes, des individus autour de leur centre de classe (la séparation entre classes dans E reste des portions d'hyperplans).

Cette troisième forme est *a priori* la distance la plus représentative des données donc, celle qui donne de meilleurs résultats. Malheureusement, les calculs de la matrice de covariance pour chaque classe et de la distance à chaque classe pour tout individu doivent être répétés à chaque itération, ce qui conduit à de longs temps de calcul pour une simple convergence.

Comme nous le verrons par la suite, nous utilisons l'algorithme des *k*-moyennes de manière intensive; le coût de l'utilisation de cette distance devenant prohibitif, nous l'avons délaissée au profit des deux premières distances qui fournissent malgré tout de très bons résultats.

#### Algorithmie

L'algorithme de descente utilisé dans les k-moyennes est une adaptation [FORG-65] de celui décrit précédemment :

1. 
$$it = 0$$

- 2. choisir les centres initiaux :  $\{v_1^{(it)} .. v_c^{(it)}\}$
- 3. it = it + 1
- 4. actualiser chaque classe suivant:

$$\omega_i^{(it)} = \{ x_k \in X, \ d(x_k, v_i^{(it-1)}) \le d(x_k, v_j^{(it-1)}) \ \forall j \neq i \}$$
(5.1)

5. si une classe est vide retourner en 2 (en effectuant un autre choix) sinon actualiser chaque centre suivant:

$$v_i^{(it)} = \frac{1}{\operatorname{card}\omega_i^{(it)}} \sum_{x_k \in \omega_i^{(it)}} x_k$$
(5.2)

6. si  $\exists i, \ \omega_i^{(it)} \neq \omega_i^{(it-1)}$  alors retourner à l'étape 3

#### Variantes

Plusieurs variantes de cet algorithme existent. Citons pour exemple celle, plus lente, qui réestime le centre d'une classe dès qu'un nouvel individu est affecté à cette classe ou qu'un de ses individus est affecté à une autre classe [MCQU-67].

Cet algorithme a été raffiné en ISODATA [BALL-67], pour *Iteratif Self-Organizing Data Analysis Techniques (A)*. A l'issue d'une itération, on procède à un examen de la classification obtenue et on s'autorise à la modifier. Par exemple, si une classe contient trop peu d'individus, ces derniers sont réaffectés dans les autres classes et celle-ci disparaît; si au contraire elle en contient trop, elle sera divisée en deux classes; si deux classes sont trop proches, elles sont fusionnées.

Le comportement d'ISODATA est réglable par sept paramètres qui permettent de définir les règles de suppression, division et regroupement de classes. Malheureusement, la nécessité de tels réglages rend son emploi répétitif délicat, particulièrement lorsque les jeux de données à classifier sont très hétérogènes.

Enfin, notons que plus un individu est éloigné du centre de sa classe, plus sa contribution au calcul de la fonction objectif est élevée. Or si cet individu est à distance (à peu près) équivalente du centre de sa classe et de celui d'une autre classe, son appartenance dans la classification est incertaine. Afin qu'il n'influence pas le dessin itératif des classes, ce type d'individu peut être omis dans le calcul du noyau des classes.

Cette version de la méthode des k-moyennes est biaisée car, si ces individus sont en petit nombre, leur éventuelle contribution est importante du fait de leur distance aux classes ; les oublier modifie beaucoup le comportement de la convergence et rend son résultat douteux.

### 5.1.4 Exemples d'application en IRM

L'intérêt de la méthode des k-moyennes réside dans sa simplicité et sa grande vitesse d'exécution, même avec un nombre important d'individus. C'est donc une méthode très attrayante pour obtenir rapidement une première classification.

Dans [GERI-92], elle est appliquée sous sa forme ISODATA sur un jeu de 16 images possédant chacune deux échos. Puis, les résultats obtenus sont comparés à ceux d'une méthode supervisée (fenêtres de Parzen). Les taux de reconnaissance respectifs sont de 87,5% et 93,8% ce qui laisse supposer que les méthodes automatiques peuvent égaler, au prix d'améliorations, les méthodes supervisées.

Dans [VEIJ-94], les k-moyennes sont utilisées comme étape d'apprentissage d'une méthode supervisée.

# 5.2 Résultats obtenus avec les k-moyennes

# 5.2.1 Choix méthodologiques

En ce qui concerne l'obtention des centres initiaux, de nombreuses options sont disponibles dans la littérature [ANDE-73].

Prendre en compte le fait que le type d'acquisition ( $\rho$ ,  $T_1$  ou  $T_2$ ) donne une indication sur les valeurs recherchées des centres des classes n'est pas d'une très grande utilité. La convergence s'arrête de toute façon au premier minimum local rencontré, et celui-ci n'est pas obligatoirement suffisamment proche de la solution optimale.

Pour s'affranchir de ce problème, nous avons opté pour l'emploi d'une approche empirique ; nous effectuons plusieurs exécutions de l'algorithme de descente, les centres initiaux étant à chaque fois tirés aléatoirement. Finalement, nous conservons le résultat de la descente particulière, qui correspond au minimum des différentes valeurs de la fonction objectif, obtenues à l'issue des descentes.

Le nombre d'exécutions est limité (nous avons fixé arbitrairement à 1000 cette limite) mais la méthode s'arrête lorsqu'un certain nombre d'exécutions successives (fixé à 50) n'ont pas permis d'améliorer le minimum.

Enfin, comme nous classifions les voxels d'après leur radiométrie, nous pouvons modifier les formules (5.1) et (5.2) pour effectuer les actualisations à l'aide de l'histogramme des radiométries de l'image.

Soit  $X_R = \{r_j\}$  l'ensemble des vecteurs radiométriques d'occurrence non nulle dans l'image à classifier tel que :

$$\forall r_j \in X_R \quad \forall r_{j'} \in X_R \quad (j' \neq j) \Rightarrow (r_j \neq r_{j'})$$

Comme la classification a pour espace des caractéristiques, l'espace des radiométries, on a  $X_R \subset X$ . Par définition, chaque vecteur radiométrique  $r_j$  de  $X_R$  a dans l'image au moins un voxel représentant, et tout vecteur caractéristique d'un voxel de l'image appartient à  $X_R$ . Cela peut s'écrire :

$$\forall x_k \quad \exists j \text{ tel que } x_k = r_j.$$

Nous pouvons définir les ensembles  $X_j \subset X$  des vecteurs caractéristiques de même valeur :

$$X_j = \{ x_k, x_k = r_j \}.$$

Par construction:

$$X = \bigcup_j X_j.$$

Notons h la fonction histogramme de l'image :

$$h: \left\{ \begin{array}{ccc} X_R & \Leftrightarrow & \mathbf{N}^* \\ r_j & \Leftrightarrow & h(r_j). \end{array} \right.$$

La formule (5.1) devient alors :

$$\omega_i^{(it)} = \{ X_j \subset X, \ d(r_j, v_i^{(it-1)}) \le d(r_j, v_{i'}^{(it-1)}) \ \forall i' \ne i \} ;$$
(5.3)

quant à la formule (5.2), elle devient :

$$v_{i}^{(it)} = \frac{\sum_{j=1, X_{j} \subset \omega_{i}^{(it)}}^{\operatorname{card}(X_{R})} h(r_{j}) r_{j}}{\sum_{j=1, X_{j} \subset \omega_{i}^{(it)}}^{\operatorname{card}(X_{R})} h(r_{j})}.$$
(5.4)

La classification se calcule ainsi sur l'ensemble des vecteurs radiométriques  $r_j$  et non plus sur l'ensemble beaucoup plus peuplé des  $x_k$  (card( $X_R$ )  $\ll$  card(X)).

# 5.2.2 Résultats bruts

Pour tester la classification à l'aide de l'algorithme des k-moyennes, nous utilisons de nouveau l'image bi-modalité ( $xavT_1$  et  $xavT_2$ ).

Les centres radiométriques (k-moyennes) obtenus à l'issue de la procédure décrite précédemment, pour différents nombres de classes et pour les distances  $L_1$  et  $L_2$ , sont regroupés dans le tableau 5.1. Nous avons trouvé expérimentalement que la classification se rapprochant le plus de la segmentation attendue correspond à un nombre de classes valant 7; la figure 5.1 permet d'apprécier ce résultat qui souffre cependant des imperfections suivantes:

- le cortex est rogné du côté de son interface avec la substance blanche,
- du côté de son interface avec le liquide céphalo-rachidien, le cortex, en revanche, mord sur les sillons qui, trop fins, sont partiellement segmentés,
- la substance grise des noyaux gris est à peine segmentée, la substanche blanche prenant le dessus,
- le volume partiel entre ventricule et substance blanche est segmenté comme substance grise.



FIG. 5.1 - Classification par k-moyennes

Cette figure correspond à la coupe n°62 de  $x avT_1$ . L'image de gauche correspond à l'acquisition IRM 3D; l'image de droite correspond à une segmentation en 7 classes obtenue par l'utilisation empirique de l'algorithme des k-moyennes avec la distance  $L_1$ . Les classes reconnues sont, de la plus foncée à la plus claire : air + os (1); liquide céphalo-rachidien (2); substance grise (3); substance blanche (4); muscle (5); peau + graisse (6); quelques points dus au décalage chimique (7).

# 5.2.3 Influence de la distance

Nous avons remarqué au cours de nos expériences que lorsque le nombre de classes reste faible, l'utilisation au cours des descentes d'une distance particulière ne modifie pas les k-moyennes résultantes. En revanche, lorsque le nombre de classes est important, les k-moyennes obtenues différent grandement suivant le choix de la fonction distance; nous verrons par la suite que nous ne nous placerons jamais dans ce cas de figure. Notons que le tableau 5.1 vérifie cette remarque pour  $k \leq 7$ .

Pour ces cas favorables, nous avons donc tout intérêt à opter pour l'emploi de la distance  $L_1$ , beaucoup plus rapide à calculer que  $L_2$ , le gain en temps de calculs étant d'autant plus élevé que la dimension de E est grande.

La région de décision d'une classe est l'ensemble des vecteurs de E qui se voient attribuer la classe en question; interrogeons-nous maintenant sur la pertinence de la forme des régions de décision représentées sur la figure 5.2.

Comme chaque individu appartient à la classe de plus proche centre, lorsque  $L_2$  est employée, l'ensemble des régions constitue dans E un pavage de Voronoï. Ce dernier paraît très acceptable si nous ne possédons pas d'informations supplémentaires quant à la forme même des classes de X.

Lorsque  $L_1$  est employée, les pavés résultants ne conservent pas la topologie précédente. Nous pouvons même observer le fait que certaines zones de E, entièrement comprises dans la région de décision d'une classe au sens de  $L_2$ , se retrouvent dans la région de décision d'autres classes au sens de  $L_1$ .

De telles régions « litigieuses » se situent à la frontière entre régions de décisions ; elles concernent les voxels de rejet en ambiguïté mentionnés en section 4.2.2. Or ils sont en nombre important car correspondent, en très grande partie, aux voxels de mélange présents massivement en IRM 3D. En effet,

k	d	centres (couples radiométriques $T_1 T_{2a}$ )
2	$L_1$	16 8 - 66 64
2	$L_2$	11 8 - 67 60
3	$L_1$	98-5193-7341
3	$L_2$	9 8 - 48 94 - 74 41
4	$L_1$	9 8 - 45 98 - 69 43 - 124 53
4	$L_2$	8 8 - 47 95 - 70 40 - 130 62
5	$L_1$	7 8 - 35 124 - 66 16 - 66 62 - 133 62
5	$L_2$	7 8 - 34 129 - 65 63 - 66 16 - 130 60
6	$L_1$	7 8 - 30 140 - 52 73 - 65 15 - 77 55 - 145 68
6	$L_2$	7 8 - 31 141 - 51 74 - 64 14 - 77 54 - 143 66
7	$L_1$	6 7 - 29 143 - 51 78 - 47 20 - 75 56 - 83 12 - 140 75
7	$L_2$	6 7 - 30 143 - 51 77 - 45 19 - 75 55 - 80 13 - 145 71
8	$L_1$	6 7 - 29 143 - 51 78 - 42 23 - 73 11 - 75 56 - 118 30 - 135 93
8	$L_2$	6 7 - 30 143 - 51 77 - 45 19 - 75 55 - 80 13 - 124 80 - 180 39
9	$L_1$	6 7 - 25 156 - 55 68 - 43 20 - 46 100 - 75 11 - 78 54 - 124 31 - 138 95
9	$L_2$	6 7 - 29 145 - 53 80 - 27 43 - 52 13 - 74 55 - 85 14 - 125 80 - 189 41

TAB. 5.1 – k-moyennes obtenues empiriquement pour l'image bi-modalité ( $xavT_1$ ;  $xavT_{2a}$ )



FIG. 5.2 – Espaces de décision en fonction de d

l'effet de volume partiel produit un véritable étalement des occurrences des vecteurs radiométriques entre les centres radiométriques de classes voisines dans l'image (phénomène observable sur la figure 4.1).

Les frontières radiométriques entre régions de décision ont donc un poids non négligeable; les déplacer légèrement entraîne le passage d'une quantité importante de voxels de mélange (situés dans l'image à l'interface entre deux structures) d'une classe à une autre (chaque classe représentant une

des deux structures).

## 5.2.4 Fiabilité de la procédure

Pour observer la présence de nombreux minima dans l'allure de la fonction objectif, nous avons procédé à de multiples descentes et ce, avec différents nombres de classes.

Pour un k donné, les centres retenus à l'issue de chaque descente, vecteurs radiométriques de dimension 2, ont donné lieu à un comptage que la figure 5.3 visualise. Les pics d'occurrences y sont portés en gris; plus le gris est foncé, plus le nombre d'occurrences est important, ce qui signifie que le centre correspondant est plus souvent solution à l'issue des descentes. Les régions blanches traduisent le fait que les vecteurs qu'elles contiennent ne sont pas apparus comme centres solution lors des multiples descentes.

Des résultats que nous avons obtenus, nous pouvons tirer plusieurs observations.

Tout d'abord, les pics significatifs sont regroupés dans des vallées témoignant de l'organisation des minima de la fonction objectif. Si la plupart des descentes ont pour résultat de placer un centroïde dans chaque vallée, beaucoup aboutissent à des centroïdes aberrants. Ces derniers échouent en effet dans des minima très locaux ; cela se traduit sur les graphiques de la figure 5.3 par la présence de multiples points répartis sur E.

L'utilisation des *k*-moyennes ne peut donc se concevoir comme une descente unique, le risque d'obtention d'une classification erronée (trop éloignée de la classification recherchée) étant non négligeable. Pour garantir qu'une solution est suffisamment proche de la solution optimale, il est nécessaire de recourir soit à de multiples descentes soit à un procédé d'optimisation globale.

Comme nous avons déjà opté pour la première possibilité, nous nous devons de vérifier que le protocole empirique nous permet effectivement d'obtenir une solution correcte.

Pour cela, nous avons mesuré *a posteriori* pour chaque descente (notée *it*) prise parmi les 1000, l'écart  $e^{(it)}$  de son résultat final (centres  $v_i^{(it)}$  avec i = 1..k) au résultat optimal (centres  $v_i^{(opt)}$  avec i = 1..k minimisant la mesure de dissimilarité):

$$e^{(it)} = \frac{1}{k} \sum_{i=1}^{k} d\left(v_i^{(it)}, v_i^{(opt)}\right)$$

La figure 5.4 illustre le comptage des 1000 écarts pour différentes valeurs de k; nous avons pris  $d = L_1$  donc les  $e^{(it)}$  sont entiers et leur occurrence significative.

Nous remarquons en règle générale que lorsque k augmente, la proportion d'obtention de kmoyennes proches des centres optimaux diminue (le pourcentage d'écarts faibles décroît). Pire, l'écart moyen entre un résultat de descente et le résultat optimal augmente, comme l'indique le tableau 5.2.

Aussi, plus le nombre de classes est élevé, plus cette approche empirique nécessite de descentes afin de garantir un résultat proche de l'optimal.

# **5.3** Algorithme des *c*-moyennes floues

Les ensembles flous [ZADE-65] fournissent un cadre théorique rigoureux dont on peut exploiter les richesses en classification automatique.

Les vecteurs caractéristiques des individus à classifier sont généralement connus avec une certaine imprécision; en IRM, celle-ci est due au bruit et à l'effet de volume partiel (Cf. partie I). Les



FIG. 5.3 – Localisation des k-moyennes

Ces figures représentent, pour différents nombres k de classes recherchées, l'histogramme des centroïdes (vecteurs radiométriques 2D) résultants de 1000 exécutions de l'algorithme de descente des k-moyennes.



FIG. 5.4 – Histogrammes des écarts aux k-moyennes optimales

Chaque graphique représente, pour un nombre k donné de classes et pour 1000 descentes de l'algorithme des k-moyennes, les occurrences (en logarithme) des écarts entre l'ensemble des centres issu de chaque descente et l'ensemble des centres optimaux ; notons que l'augmentation de k diminue la fréquence empirique d'obtention des centres optimaux (écart nul) et, plus généralement, rend plus délicat l'obtention de centres proches de ceux recherchés (la surface de la « bosse » des écarts très erronés grossit).

$(aab \pm 1), aab \pm 2a)$					
	k	$e^{(it)}$ moyen	% age $e^{(it)} < 5$		
	4	12	56.9		
	5	11	75.2		
	6	14	82.6		
	7	21	51.6		
	8	28	06.0		
	9	28	18.4		

TAB. 5.2 – Écart moyen entre les k-moyennes issues de descentes successives et les k-moyennes optimales pour l'image bi-modalité ( $xavT_1$ ;  $xavT_{2a}$ )

méthodes floues permettent de prendre en compte cette imprécision grâce à la modélisation du degré de l'appartenance d'un individu à chaque classe.

De plus, la comparaison des degrés d'appartenance d'un individu aux différentes classes apporte un renseignement quant à l'aspect litigieux de la classification de cet individu (nous avons discuté ce problème en section 5.2.3). La théorie des ensembles flous nous permet donc de traiter après classification le problème des voxels de rejet (section 4.2.2).

#### 5.3.1 Notion de partition floue

Au cours d'un algorithme de classification non floue, un individu est attribué à une unique classe. En revanche, en classification floue, un individu  $x_k$  possède une valeur d'appartenance pour chaque classe  $\omega_i$ ; comprise entre 0 et 1, elle est notée  $u_{ik}$ . Une appartenance proche de 1 pour un individu et une classe indique une excellente adéquation entre l'individu et la classe, et une valeur proche de 0, une piètre adéquation.

Les valeurs d'appartenance constituent donc une matrice à c lignes (une ligne par classe à former) et n colonnes (une colonne par individu à classifier):

$$U = [u_{ik}]_{i=1...c\ k=1...n}$$

Pour chaque individu, la colonne correspondante de U représente un vecteur d'appartenance, chaque ligne de ce vecteur contenant la valeur d'appartenance de l'individu pour la classe correspondante.

U est dite matrice de la c-partition floue lorsque deux contraintes sont imposées.

La première traduit que l'appartenance d'un individu est répartie sur l'ensemble des classes ; elle s'écrit :

$$\sum_{i=1}^{c} u_{ik} = 1 \quad \forall k = 1 \dots n .$$
 (5.5)

Dans le cadre d'une classification classique, l'intégrité d'un individu impose son appartenance à une classe unique :

$$\forall k = 1 \dots n \quad \exists i \in 1 \dots c \quad \text{tel que} \quad x_k \in \omega_i$$

ce qui se traduit par :

$$\begin{array}{l} \left(\begin{array}{c} x_k \in \omega_i \end{array}\right) \\ \Leftrightarrow & \left(\begin{array}{c} u_{ik} = 1 \end{array}\right) \\ \Leftrightarrow & \left(\begin{array}{c} u_{jk} = 0 \end{array}\right) \forall j = 1 \dots c \text{ avec } j \neq i \end{array} \right) \,. \end{array}$$

La seconde contrainte s'écrit :

$$0 < \sum_{k=1}^{n} u_{ik} < n \quad \forall i = 1 \dots c ,$$
 (5.6)

et exprime que la classification ne produit pas de classe vide (et donc, qu'elle ne produit pas une unique classe comportant tous les individus). Dans le cadre d'une classification classique, cette contrainte est toujours vérifiée puisque:

$$\sum_{k=1}^{n} u_{ik} = \operatorname{card}(\omega_i) \quad \forall i = 1 \dots c \,.$$

# **5.3.2** Adaptation floue des *k*-moyennes

Dunn [DUNN-74] a été le premier à proposer une adaptation au formalisme flou de l'algorithme des k-moyennes, version généralisée ensuite par Bezdek [BEZD-73]. L'algorithme des c-moyennes floues (FCM, pour *fuzzy c-means*) consiste, comme son modèle non flou, à partitionner X en c classes sous le contrôle d'une fonction objectif.

Soit  $\| \|_A$  une norme liée à la matrice définie positive A :

$$||x||_A^2 = x^t A x.$$

La fonction objectif a l'expression suivante :

$$J(U,V) = \sum_{i=1}^{c} \sum_{k=1}^{n} u_{ik}^{m} \|x_{k} \Leftrightarrow v_{i}\|_{A}^{2} ,$$

avec m > 1 facteur de flou et  $|| ||_A$  norme. Pour un ensemble donné de vecteurs  $x_k$  de E avec  $k = 1 \dots n$ , on recherche donc l'ensemble  $V = (v_1 \dots v_i, \dots v_c)$  des centroïdes des classes et la matrice de c-partition floue U qui minimisent J. La principale difficulté de la recherche des variables optimales provient de la non-convexité de la fonction objectif: J posséde des minima locaux (et des points selle) dans lesquels s'échouent les procédés classiques de descente.

Pratiquement, on prend m dans l'intervalle de 1,5 à 2,5. Sa présence a pour but de régler la force du flou ; plus il est élevé, moins il discrimine les individus ayant une forte appartenance à une classe particulière de ceux qui sont partagés entre plusieurs classes.

La minimisation de J, toujours sous les contraintes (5.5) et (5.6), est obtenue par un procédé itératif similaire à celui des k-moyennes :

- 1. Initialiser le numéro de l'itération it à 0. Choisir un ensemble de centres initiaux  $v_i^{(0)}$  pour  $i = 1 \dots c$ .
- 2. Incrémenter *it*.

Mettre à jour la matrice de partition floue en calculant ses coefficients :

$$u_{ik}^{(it)} = \frac{\left\| x_k \Leftrightarrow v_i^{(it-1)} \right\|_A^{\frac{2}{1-m}}}{\sum_{l=1}^c \left\| x_k \Leftrightarrow v_l^{(it-1)} \right\|_A^{\frac{2}{1-m}}} \quad \forall i = 1 \dots c \quad \forall k = 1 \dots n$$
(5.7)

3. Mettre à jour les centres des classes floues suivant la formule :

$$v_i^{(it)} = \frac{\sum_{k=1}^n u_{ik}^{(it)m} x_k}{\sum_{k=1}^n u_{ik}^{(it)m}} \quad \forall i = 1 \dots c$$
(5.8)

4. Comparer les nouveaux centres  $v_i^{(it)}$  avec les anciens  $v_i^{(it-1)}$ . Si aucun changement significatif n'est observé alors s'arrêter sinon retourner en 2.

Pour un espace E de dimension p élevée, on préférera une norme  $L_1$  pour sa rapidité de mise en œuvre :

$$||x||_{L_1}^2 = |x^{(1)}| + \dots + |x^{(p)}|.$$

La simplification de la classification donnée en section 5.2.1 page 87 pour l'algorithme des k-moyennes s'étend aussi à l'algorithme des c-moyennes floues. Puisque seule la radiométrie intervient comme caractéristique d'un voxel, nous avons pour chaque classe d'indice i:

$$\forall j \; \forall x_k \in X_j \quad u_{ik}^{(it)} = \mu_{ij}^{(it)} ,$$

avec  $\mu_{ij}^{(it)}$  la valeur d'appartenance floue du vecteur radiométrique  $r_j$  à la classe d'indice *i*, valeur à l'itération *it*.

Les formules de mises à jour 5.7 et 5.8 deviennent respectivement :

$$\mu_{ij}^{(it)} = \frac{\left\| r_j \Leftrightarrow v_i^{(it-1)} \right\|_A^{\frac{2}{1-m}}}{\sum_{l=1}^c \left\| r_j \Leftrightarrow v_l^{(it-1)} \right\|_A^{\frac{2}{1-m}}} \quad \forall i = 1 \dots c \quad \forall j = 1 \dots \text{card}(X_R) ,$$

et

$$v_i^{(it)} = \frac{\sum_{j=1}^{\operatorname{card}(X_R)} h(r_j) \,\mu_{ij}^{(it)m} \,r_j}{\sum_{j=1}^{\operatorname{card}(X_R)} h(r_j) \,\mu_{ij}^{(it)m}} \quad \forall i = 1 \dots c \,.$$
(5.9)

Enfin, une ultime étape est nécessaire si l'on souhaite obtenir une classification non floue à l'issue de la classification floue; on parle de « défuzzification ». Lorsque l'on ne souhaite ni mettre en évidence les voxels ambigus, ni faire intervenir d'autres informations (par fusion) avant de réaliser la défuzzification, une façon naturelle de procéder est de considérer que la classe finale d'un voxel est celle qui maximise ses valeurs d'appartenance:

$$\forall k = 1 \dots n \quad x_k \in \omega_i \iff \left( \begin{array}{c} \mu_{ij}^{(it)} \ge \mu_{i'j}^{(it)} \quad \forall i' \neq i \end{array} \right), \tag{5.10}$$

avec j tel que  $x_k \in X_j$  et it l'indice de la dernière itération de l'algorithme des c-moyennes floues.

Contrairement à l'algorithme des k-moyennes où une décision nette est prise à chaque itération, l'algorithme des c-moyennes floues repousse une éventuelle étape de décision à la fin de la convergence.

# 5.3.3 Résultats

Nous avons mené une classification en quatre classes à l'aide de l'algorithme des c-moyennes floues sur une image 3D constituée d'une unique acquisition, modification de  $xavT_1$  telle que les voxels extérieurs au cerveau aient une radiométrie de 0 (une description de la segmentation du cerveau est donnée en section 7.2).

L'algorithme a été inclus dans la même procédure répétitive que celle décrite en section 5.2.4 afin de rendre son résultat plus robuste. Extension à la théorie des ensembles flous de l'algorithme des *k*-moyennes, il a le même comportement mais, de fonction objectif différente, ne donne pas *a priori* le même résultat. Néanmoins, les résultats après défuzzification des classes floues obtenues par l'algorithme des *c*-moyennes floues sont comparables à ceux qui sont obtenus par l'algorithme des *k*-moyennes comme le montrent les figures 5.1 page 89 et 5.5.



FIG. 5.5 – Résultat non flou de classification floue

A partir d'une image du cerveau issue d'une unique acquisition (a), nous menons une classification floue par l'algorithme des *c*-moyennes floues ; les classes sont au nombre de quatre : fond, liquide céphalo-rachidien, substance grise ou substance blanche. Au final (b), un voxel est affecté à la classe pour laquelle son appartenance floue est maximale.

Une différence notable concerne cependant la classe correspondant au fond de l'image. Pour les k-moyennes, nous avons utilisé une acquisition brute tandis que pour les c-moyennes, nous nous sommes restreints à la segmentation du cerveau. La notion de fond d'image n'a donc pas la même signification.

Dans le premier cas, il s'agit non seulement de l'air, mais aussi de l'os dont la loi radiométrique est très proche de celle de l'air; le bruit et l'effet de volume partiel aidant, l'histogramme présente alors un mode (à l'extrême gauche de la figure 2.7 page 42) qui est bien détecté par les k-moyennes.

Dans le second cas, les voxels extra-cérébraux ont une radiométrie fixée à 0 et l'histogramme présente alors un pic pour cette valeur; la classe est bien détectée mais l'étalement radiométrique de la fonction d'appartenance floue correspondante empiète sur les radiométries du liquide céphalo-rachidien. Des voxels étiqueté fond apparaissent donc parmi ceux du liquide (voxels blancs de la figure 5.5).

Nous reparlons de ce phénomène en section 5.4.3 où une méthode de classification floue donne avec cette image à fond uni des résultats correctes (figure 5.12 page 109).

Les cinq diagrammes des figures 5.6 et 5.7 montrent pour chaque niveau radiométrique sa valeur d'appartenance à chaque classe; le seul facteur qui diffère d'un diagramme à un autre est la valeur m du facteur de flou.

Sur la première figure, ses valeurs sont extrêmes. Avec m = 1, 1 le classifieur se comporte presque comme son équivalent non flou, l'algorithme des k-moyennes; les valeurs finales d'appartenance pour l'ensemble des radiométries sont proches soit de 0 soit de 1. Avec m = 6, 0 le classifieur est si flou que pour la plupart des radiométries, les différentes valeurs d'appartenance sont du même ordre de grandeur; seules les radiométries proches du centre d'une classe ont une valeur d'appartenance élevée (pour cette classe justement) relativement aux autres classes.



FIG. 5.6 – Comportement extrême des c-moyennes floues

Ces schémas représentent l'allure des fonctions d'appartenance floue à l'issue de deux classifications où le facteur de flou diffère ; il est trop faible pour la première classification (à gauche) et trop élevé pour la seconde (à droite).

Les valeurs de m comprises entre 1,5 et 2,5 ne tombent pas dans ces travers (figure 5.7): lorsque m est proche de 1,5, la forme des fonctions d'appartenance est plutôt trapézoïdale tandis que lorsque m augmente, cette forme devient parabolique (vers m = 2,0) puis triangulaire (vers m = 2,5). Les images des classes floues obtenues au final pour m = 1,5 et m = 2,5 sont montrées en figure 5.8, respectivement en colonnes de gauche et de droite. La classification où m = 1,5 est bien effectivement moins floue que celle où m = 2,5.

Notons que, lorsque le facteur de flou varie dans cet intervalle, la fonctionnelle à optimiser diffère et l'algorithme des c-moyennes floues ne produit pas exactement les mêmes résultats. Après défuzzification des classification floues finales, les résultats sont extrèmement similaires; l'explication est triviale : des centres radiométriques finals étant donnés, pour toute radiométrie, modifier m ne change pas l'ordre des valeurs d'appartenance floue aux différentes classes.

# 5.3.4 Critiques

Comme nous pouvons le constater sur les courbes de la figure 5.7, la forme des fonctions d'appartenance n'est pas satisfaisante car ces dernières ne vérifient pas la propriété de décroissance globale lorsque la radiométrie s'éloigne de la radiométrie moyenne d'une classe. En effet, toute fonction d'appartenance d'une classe donnée est localement croissante dans les régions radiométriques si-


FIG. 5.7 – Comportement « normal » des c-moyennes floues

Contrairement à la figure 5.6, les valeurs du facteur de flou sont dans un intervalle raisonnable; la forme des fonctions d'appartenance passe d'une allure trapézoïdale (flou léger) à une allure parabolique (flou moyen) puis à une allure triangulaire (fort flou).



FIG. 5.8 – Classes floues par l'algorithme des c-moyennes floues

Ces images montrent les classes obtenues par l'algorithme des *c*-moyennes floues sur une acquisition en  $T_1$  où les voxels extra-cérébraux ont été mis à la valeur de radiométrie 0. Les niveaux de gris sont proportionnels aux valeurs d'appartenance; le noir traduit une valeur d'appartenance nulle et le blanc une valeur maximale de 1. Les colonnes de gauche et de droite correspondent à des facteurs de flou *m* valant respectivement 1, 5 et 2, 5; de haut en bas, les lignes représentent les classes : fond, liquide céphalo-rachidien, substance grise et substance blanche. tuées entre deux classes de centres successifs et différentes de la classe considérée; de plus, la classe de plus grande caractéristique radiométrique voit sa fonction d'appartenance diminuer pour des radiométries supérieures à sa caractéristique alors que les voxels correspondant appartiennent complètement à cette classe.

La forme des fonctions d'appartenance, induite par l'expression de la fonctionnelle à minimiser et définie par la formule (5.7), n'est pas acceptable si nous utilisons ultérieurement le résultat des *c*-moyennes floues dans le cadre d'une procédure de fusion floue [BLOC-94b].

Comme l'algorithme des c-moyennes floues a un comportement similaire à celui des k-moyennes mais est plus gourmand en temps de calcul que ce dernier, comme les fonctions d'appartenance floue finales présentent des défauts, une approche en deux temps peut être envisagée pour l'obtention d'une classification floue (dont la philosophie serait proche de celle des c-moyennes floues):

- 1. calculer les centres des classes par répétition de l'algorithme des k-moyennes (section 5.2.4);
- 2. calculer les fonctions d'appartenance floue pour chaque classe.

La seconde étape consiste à choisir un modèle pour les fonctions d'appartenance floue. Dans le cas d'une acquisition unique, la caractéristique radiométrique d'un voxel est numérique et non vectorielle; les fonctions d'appartenance floue des classes exprimées en fonction de la radiométrie peuvent par exemple avoir l'allure de trapèzes, de paraboles ou de triangles pour les classes dont la moyenne radiométrique n'est ni la plus faible ni la plus forte; chaque fonction à une valeur de 1 pour le centre de classe et décroît jusqu'à 0 lorsque l'on s'éloigne de ce centre. Pour ces deux classes extrêmes, nous pouvons reprendre l'allure choisie, en la modifiant de telle façon que la fonction sature à 1, respectivement pour les radiométries très faibles et très fortes.

Une seconde solution est l'algorithme des *c*-moyennes possibilistes proposé dans [KRIS-93]. La contrainte de normalisation (5.5) est relâchée et remplacée par :

$$\max_{i=1...c} u_{ik} > 0 \quad \forall k = 1...n$$

qui signifie qu'un individu doit appartenir partiellement à au moins une classe. La fonction objectif est modifiée et sa nouvelle expression impose que les fonctions d'appartenance soient de la forme :

$$u_{ik}^{(it)} = \frac{1}{1 + \left(\frac{\left\|x_k - v_i^{(it-1)}\right\|_A^2}{\eta_i}\right)^{\frac{1}{m-1}}}$$

Les deux différences principales avec la formule équivalente (5.7) pour les *c*-moyennes floues sont d'une part qu'une valeur d'appartenance d'un individu à une classe ne dépend plus que de cette classe et d'autre part, que les fonctions d'appartenance ont une forme acceptable.

Quant à la mise à jour des centres des classes, elle conserve sa forme (5.8).  $\eta_i$  détermine la distance au centre de la classe pour laquelle la valeur d'appartenance vaut 1/2; cette valeur peut être fixée ou, comme elle caractérise l'étalement des caractéristiques d'une classe, estimée à chaque itération; dans ce dernier cas, la convergence n'est pas toujours garantie.

#### 5.4 Apprentissage automatique de fonctions d'appartenance floue

Cette section est en grande partie fondée sur [BLOC-97a]. Elle présente une nouvelle approche non supervisée du problème de l'estimation des fonctions d'appartenance ; l'idée principale de cette approche est l'introduction de contraintes intuitives <sup>1</sup> sur la forme des fonctions d'appartenance.

#### 5.4.1 Les transformations histogramme/fonctions d'appartenance

#### Passage d'une distribution de probabilité à une distribution de possibilité

L'histogramme d'une image s'interprète facilement en termes probabilistes comme étant la distribution de probabilité des niveaux de gris dans cette image; en effet, la probabilité d'apparition d'un niveau de gris dans une image est le nombre d'occurrences de ce niveau dans cette image sur le nombre total de points de cette image.

Plusieurs méthodes ont été proposées dans la littérature pour transformer une distribution de probabilité  $p_k$  en une distribution de possibilité  $\pi_k$  (et inversement), lorsque les deux distributions sont discrètes ( $1 \le k \le K$ ) [DUBO-83][BHAR-85][KLIR-92]. Les principales contraintes pour réaliser ces transformations sont :

- la conservation du rang,
- la normalisation,
- la cohérence probabilité-possibilité:
  - $-\pi_k \le p_k$  [DELG-87],
  - ou  $\sum_{k=1}^{K} p_k \pi_k = c$  avec c constante dans [0,1] [ZADE-78],
  - ou la conservation de l'incertitude en utilisant l'entropie [KLIR-92].

Plus de détails sur ces méthodes et sur leur comparaison sont donnés dans [KLIR-92].

#### De données statistiques à des fonctions d'appartenance

La définition de fonctions d'appartenance à partir de données statistiques, comme nous l'avons vu en section 5.3, s'effectue classiquement à l'aide de l'algorithme des *c*-moyennes floues. Une autre méthode consiste à définir ces fonctions par l'optimisation de critères comme l'entropie floue [CHEN-95] ou le minimum de la spécificité et de la cohérence [CIVA-86][CHAU-95].

#### L'utilisation de critères a posteriori

Une autre approche consiste en la minimisation des erreurs de classification. Ces dernières sont fondées sur un critère *a posteriori* car elles prennent en considération la procédure de classification avec sa règle de décision. Une telle méthode est proposée dans [YAN-96] et fait intervenir des intégrales floues pour l'étape de combinaison.

#### Limites des méthodes existantes

Les méthodes présentées dans les deux premiers paragraphes de cette section optimisent un critère *a priori* lié à la ressemblance entre l'histogramme de l'image (ou la distribution de probabilité) et les fonctions désirées. A l'inverse, les méthodes du dernier paragraphe incluent dans l'optimissation la procédure de classification ce qui suppose qu'elle est connue.

<sup>1.</sup> Ces contraintes sont générales, et ne nécessitent donc aucune information experte liée au domaine d'application de la classification.

Comme nous voulons estimer les fonctions d'appartenance afin de les utiliser pour classifier, nous préférons la philosophie des premières méthodes. Cependant elles présentent un inconvénient majeur : la plupart des critères fournissent des fonctions qui dépendent de la forme de l'histogramme et qui s'appuient principalement sur les modes (bosses) de l'histogramme, délaissant les voxels dont les radiométries sont de faible occurrence et qui pourtant forment de véritables classes (les vaisseaux sanguins par exemple). De plus, certaines méthodes calculent souvent les fonctions d'appartenance une par une et non de façon globale.

#### 5.4.2 Des niveaux de gris aux fonctions d'appartenance

Nous présentons ici une méthode originale de calcul des fonctions d'appartenance à partir de l'histogramme des niveaux de gris que l'on doit à Isabelle Bloch. Cette méthode est bien adaptée pour la classification de régions homogènes dans les images et peut facilement être étendue pour prendre en compte d'autres caractéristiques comme la présence de textures. Tout d'abord, définissons les critères que les fonctions d'appartenance doivent vérifer.

#### Critères

Deux types de critères sont utilisés simultanément. Le premier se fonde sur la « ressemblance » entre l'histogramme et les fonctions d'appartenance ; c'est donc une distance entre deux distributions (il est en cela très proche de ceux qui sont utilisés dans les méthodes existantes). Le second type fait intervenir des informations *a priori* sur la forme attendue des fonctions d'appartenance et s'appuie sur une représentation paramétrique des fonctions ; c'est ce type de critère qui permet de s'affranchir des problèmes liés aux basses occurrences. La combinaison de ces deux types de critères mène à une interprétation plus simple des fonctions obtenues au final, interprétation qui correspond mieux à la notion intuitive d'appartenance.

Nous optons pour des fonctions d'appartenance trapézoïdales; elles sont donc à rapprocher des fonctions d'appartenance floue obtenues par l'algorithme des c-moyennes floues avec un facteur de flou m = 1, 5 (figure 5.7). Elles ne dépendent que d'un petit nombre de paramètres ce qui facilite l'étape d'estimation des paramètres tout en préservant la robustesse attendue des fonctions d'appartenance. Nous conservons la notation introduite au cours des sections précédentes :

- -i est l'indice d'une classe ( $i = 1 \dots k$ ),
- -j est l'indice d'une radiométrie ( $j = 1 \dots \operatorname{card}(X_R)$ ),
- $-\mu_{ij}$  est la valeur d'appartenance à la classe d'indice *i* de la radiométrie d'indice *j*.

La fonction d'appartenance à la classe d'indice i peut alors s'écrire :

$$\mu_i: \left\{ \begin{array}{ccc} 1 \dots X_R & \Leftrightarrow & [0,1] \\ j & \leftrightarrow & \mu_i(j) = \mu_{ij}. \end{array} \right.$$

La forme de cette fonction dépend de quatre paramètres  $a_i, b_i, c_i, d_i$  dont la signification est illustrée en figure 5.9. Ces quatre paramètres sont liés d'une classe à l'autre par des contraintes ; la contrainte sur  $a_i$  s'exprime suivant:  $a_i \leq a_{i+1} \quad \forall i = 1 \dots k \Leftrightarrow 1$ ; l'expression des contraintes sur  $b_i$ ,  $c_i$  et  $d_i$ est similaire.

Une des informations *a priori* que nous souhaitons introduire est qu'un voxel dont l'appartenance à une classe *i* est sans ambiguïté doit avoir une valeur d'appartenance de 1 à cette classe, et ce quelle que soit l'occurrence de la radiométrie de ce voxel dans l'image. Une approche en deux temps est



FIG. 5.9 – Définition d'une fonction d'appartenance trapézoïdale

Une fonction d'appartenance trapézoïdale définie sur les niveaux de gris radiométriques est continue par morceaux et peut être complètement déterminée grâce à quatre paramètres.

proposée : dans le premier temps, des fonctions  $\mu'_i$  qui minimisent un critère de distance à l'histogramme sont estimées, et dans un second temps, les fonctions  $\mu_i$  sont déduites de ces premières pour satisfaire ces informations *a priori*. Les fonctions  $\mu'_i$  sont aussi trapézoïdales mais ont une valeur maximum de  $h_i$ .

La fonction objectif est définie comme la somme sur l'ensemble des classes de leur critère de distance à l'histogramme ; elle s'écrit simplement :

$$\sum_{i=1}^{k} \sum_{r_j \in D_i} (h(r_j) \Leftrightarrow \mu'_i(j))^2$$

où  $D_i$  représente l'intervalle radiométrique d'influence de la classe *i* que nous définissons un peu plus loin. Cette expression a deux caractéristiques importantes : elle prend en compte globalement toutes les classes et, pour chaque classe, les valeurs de l'histogramme qui interviennent sont limitées à un intervalle radiométrique.

Le calcul de  $D_i$  est conditionné par les propriétés que nous souhaitons voir remplies par les fonctions d'appartenance :

- dans les régions radiométriques ambiguës où deux fonctions d'appartenance se recouvrent, la contrainte de ressemblance entre les fonctions et l'histogramme est relâchée (les D<sub>i</sub> seront donc définis hors de ces régions),
- pour les radiométries extrêmes, respectivement basses par rapport à la classe de plus petite radiométrie et hautes par rapport à celle de plus grande radiométrie, les fonctions d'appartenance finales μ<sub>i</sub> ne doivent pas suivre la forme de l'histogramme mais doivent être maximales ; la contrainte de ressemblance est une nouvelle fois relâchée.

Pour  $i = 1 \dots k \Leftrightarrow 1$ , notons  $s_i$  la radiométrie à laquelle s'intersectent les fonctions  $\mu'_i$  et  $\mu'_{i+1}$  (soit  $\mu'_i(s_i) = \mu'_{i+1}(s_i)$ ); nous pouvons alors exprimer  $D_i$ .

- 1. Pour les classes non extrêmes (i=2... k-1), il vient  $D_i = [s_{i-1}, s_i]$ .
- 2. Pour la classe de plus faible radiométrie moyenne, nous imposons  $a_1 = b_1 = 0$  et il vient  $D_1 = [c_1, s_1]$ .
- 3. Pour la classe de plus forte radiométrie moyenne, nous imposons  $c_k = d_k = 255$  (si la radiométrie a 255 pour valeur supérieure) et il vient  $D_k = [s_{k-1}, b_k]$ .

Une fois que les fonctions  $\mu'_i$  sont estimées pour minimiser la fonction objectif, les fonctions d'appartenance finales en sont déduites suivant :

$$\mu_i(j) = \frac{\mu_i'(j)}{h(r_j)} \quad \forall j \; .$$

#### Méthode d'optimisation

L'optimisation de la fonction objectif est réalisée par un recuit simulé d'une façon similaire à celle suggérée dans [CHEN-95].

Comme nous l'avons déjà mentionné, un des avantages de cette méthode non supervisée est que l'optimisation est mise en œuvre d'une manière globale sur l'ensemble des classes; seul le nombre de classes doit être connu. De plus, l'histogramme n'est pris en compte que dans les régions radiométriques où il apporte une information véritablement pertinente quant à l'estimation des fonctions d'appartenance. En revanche, ces fonctions sont définies par une forme paramétrée mais en pratique des formes trapézoïdales s'avèrent suffisantes.

#### 5.4.3 Résultats

Nous reprenons l'image  $xavT_1$  utilisée en figure 5.5 page 97 pour tester cette méthode et comparer ses résultats avec ceux donnés par l'algorithme des *c*-moyennes floues.

L'apprentissage des fonctions d'appartenance a lieu sur l'histogramme de l'image ; cinq classes ont été considérées, données ici par leur radiométrie moyenne allant de la plus foncée à la plus claire : le fond, le liquide céphalo-rachidien, la substance grise, la substance blanche et le sang.

Les fonctions d'appartenance  $\mu_i$  (à l'exception de celle qui correspond au fond) sont représentées sur la figure 5.10, superposées à l'histogramme. Cette figure est comparable au schéma de la figure 5.7 page 99 pour lequel le facteur flou est m = 1, 5.



FIG. 5.10 – Fonctions d'appartenance floue apprises de l'histogramme

Les fonctions d'appartenance floue apprises de l'histogramme [BLOC-97a] sont superposées à ce dernier; elles correspondent au liquide céphalo-rachidien, à la substance grise, à la substance blanche et aux vaisseaux sanguins. Nous pouvons noter l'allure très classique de ces fonctions ainsi que la ressemblance de la forme de celles qui sont associées aux substances grise et blanche avec la forme de l'histogramme. Nous pouvons noter que cette méthode présente plusieurs avantages par rapport à celle des *c*-moyennes floues.

- La forme des fonctions d'appartenance, imposée par la méthode, est maintenant plus conforme à l'interprétation.
- La fonction d'appartenance au fond est réduite à la radiométrie de valeur 0, ce qui n'est pas réalisable avec les *c*-moyennes; en effet, leur définition en équation (5.7) les oblige à s'étaler sur une plage radiométrique allant jusqu'aux centres adjacents.
- Cette méthode nous a permis de prendre en compte une classe supplémentaire pour les voxels les plus clairs de l'image, c'est-à-dire pour les vaisseaux sanguins; une telle classe ne serait pas apparue avec les *c*-moyennes car le nombre de voxels qui la constitue est trop faible et ne constitue pas un mode radiométrique dans l'histogramme.
- L'étalement radiométrique des différentes classes peut être très variable, ce qui correspond à la réalité des données, tandis que l'algorithme des *c*-moyennes a une tendance à uniformiser cet étalement pour l'ensemble des classes [CELE-89].

Pour les trois classes qui nous intéressent en premier lieu (le liquide céphalo-rachidien, la substance grise et la substance blanche), nous pouvons calculer à partir de l'image les statistiques radiométriques des classes floues : moyennes et écarts-types. Un voxel participe au calcul des statistiques de chaque classe proportionnellement à son degré d'appartenance. Ainsi la moyenne d'une classe s'obtient de façon très similaire à la formule (5.9) suivant :

$$v_i = \frac{\sum_{j=1}^{\operatorname{card}(X_R)} h(r_j) \ \mu_i(j) \ r_j}{\sum_{j=1}^{\operatorname{card}(X_R)} h(r_j) \ \mu_i(j)} \quad \forall i = 1 \dots c ,$$

et l'écart-type suivant:

$$\sigma_i = \sqrt{\begin{array}{c} \displaystyle \sum_{j=1}^{\operatorname{card}(X_R)} h(r_j) \ \mu_i(j) \ r_j^2 \\ \frac{1}{\operatorname{card}(X_R)} h(r_j) \ \mu_i(j) \\ \sum_{j=1}^{\operatorname{card}(X_R)} h(r_j) \ \mu_i(j) \end{array}} \Leftrightarrow v_i^2 \quad \forall i = 1 \dots c \ .$$

Les résultats sont portés par le tableau 5.3; ce dernier indique aussi le nombre de voxels qui participent véritablement aux statistiques (c'est-à-dire ceux dont la radiométrie est telle que  $\mu_i(j) > 0$ ) ainsi que la norme (ou cardinalité floue) des classes floues, dénominateur des formules précédentes.

Les résultats que nous obtenons doivent être comparés à ceux des estimations statistiques réalisées sur des ensembles d'apprentissage définis manuellement (partie du haut du tableau 2.5 relative à  $xavT_1$ , page 52). Nous observons que les écarts-types obtenus automatiquement sont systématiquement plus grands ; cela est dû à l'effet de volume partiel qui est pris en compte lors de la classification automatique et dont nous nous affranchissons presque intégralement lors de l'apprentissage manuel. Cet effet se ressent aussi sur les moyennes ; en particulier sur celle du liquide céphalo-rachidien très sensible à cet effet à cause de la finesse des sillons corticaux.

classe	moyenne	écart-type	nb.voxels	norme
LCR	30.6	10.4	387539	244814.4
SBR	57.3	6.9	799805	549680.4
SBL	76.3	4.9	629314	456065.9

TAB. 5.3 – Statistiques calculées sur les classes floues

Afin de réduire l'influence de l'effet de volume partiel, nous avons calculé ces statistiques non plus sur la totalité de chaque classe floue mais sur leur  $\alpha$ -coupe avec  $\alpha = 0, 5$ . Ainsi les formules de calcul de la moyenne et de l'écart-type sont modifiées en remplaçant  $\mu_i(j)$  par :

$$\mu_i^{(\alpha)}(j) = \begin{cases} 0 & \text{si } \mu_i(j) < \alpha \\ \mu_i(j) & \text{sinon } . \end{cases}$$

Les résultats donnés dans le tableau 5.4 sont en accord avec nos prévisions : les écarts-types diminuent et les moyennes du liquide céphalo-rachidien et de la substance blanche se rapprochent de leurs valeurs estimées, respectivement 16.0 et 79.8.

TAB. 5.4 – Statistiques calculées sur les  $\alpha$ -coupes (avec  $\alpha = 0, 5$ ) des classes floues

classe	moyenne	écart-type	nb.voxels	norme
LCR	27.9	8.8	233176	208639.4
SBR	57.7	5.4	575887	487299.4
SBL	76.6	4.1	483053	415036.2

Les classes floues résultantes sont données en figure 5.11 et la classification finale après défuzzification suivant l'équation (5.10) en figure 5.12.

### 5.5 Conclusion

Dans ce chapitre, nous avons mis en œuvre plusieurs méthodes de classification automatique.

La première méthode est l'algorithme des k-moyennes en sections 5.1 et 5.2.

Nous avons montré que le résultat de la convergence des k-moyennes peut conduire à un écart radiométrique important entre les centres radiométriques obtenus et ceux que nous pourrions escompter, optimaux au sens de la fonction objectif. Une approche empirique est donc proposée : la convergence de l'algorithme est répétée jusqu'à ce que le résultat ne semble pas pouvoir être amélioré (section 5.2.1). Nous avons aussi constaté que plus le nombre de classes à distinguer (ou dit autrement, le nombre d'objets à segmenter) est important, plus l'obtention d'un résultat proche du résultat optimal est délicate.

Enfin, si nous souhaitons implanter en routine la répétition de l'algorithme des k-moyennes, nous pouvons mener les convergences avec la distance  $L_1$  puis, procéder à la prise de décision à l'aide de la distance  $L_2$ . En effet, cette première distance est la plus rapide à calculer et ses résultats sont comparables, tant que le nombre de classes reste réduit, à ceux que l'on obtient avec la distance  $L_2$  (Cf. tableau 5.1 page 90); la distance  $L_1$  nous permet de mettre en œuvre un plus grand nombre d'itérations de l'agorithme des k-moyennes garantissant ainsi un meilleur résultat. Au final, l'utilisation de



FIG. 5.11 – Classes floues données par apprentissage des fonctions d'appartenance floue à partir de l'histogramme

Ces images montrent les classes obtenues sur une acquisition en  $T_1$  (où les voxels extra-cérébraux ont été mis à la valeur radiométrique 0) par un algorithme automatique d'apprentissage des fonctions d'appartenance floue à partir de l'histogramme [BLOC-97a]. Cette figure est le pendant de la figure 5.8 page 100 produite par l'algorithme des *c*-moyennes floues à une différence près : l'image du haut montre ici la classe vaisseaux sanguins.



FIG. 5.12 – Classification par apprentissage des fonctions d'appartenance floue à partir de l'histogramme

Classification non floue résultant de la défuzzification suivant la formule (5.10) des classes montrées en figure 5.11; cette figure est le pendant de la figure 5.5 page 97 produite par l'algorithme des *c*-moyennes floues.

la distance  $L_2$  pour effectuer le calcul des classes à partir des centres obtenus avec  $L_1$  nous offre des régions de décisions de forme plus naturelle.

La deuxième méthode testée est l'algorithme des c-moyennes floues en section 5.3.

Nous avons remarqué d'une part que son comportement est très semblable à celui des k-moyennes, et d'autre part que la forme des fonctions d'appartenance floues n'est pas convenable (section 5.3.4). Plusieurs solutions sont envisageables : l'algorithme des c-moyennes possibilistes [KRIS-93] ou, plus simplement, l'algorithme des k-moyennes suivi d'une étape de « fuzzification ».

Une troisième solution fait l'objet de la section 5.4; il s'agit d'un apprentissage automatique de fonctions d'appartenance flou à partir de l'histogramme de l'image [BLOC-97a]. L'idée originale de cet algorithme provient des deux types de contraintes intuitives imposées à la forme des fonctions recherchées : cette forme s'appuie sur une représentation paramétrée et doit ressembler à l'histogramme sur les régions radiométriques d'appartenance plutôt sûre.

Les résultats obtenus sont de bonne qualité et, grâce aux contraintes, sont en accord avec l'interprétation que l'on peut attacher à une fonction d'appartenance. Cette méthode, très récente, aurait pu être utilisée dans d'autres parties du manuscrit.

# Conclusion

Cette partie avait pour but d'évaluer les apports de méthodes de reconnaissance de formes à la classification des différentes matières cérébrales en imagerie par résonance magnétique tridimensionnelle, et d'illustrer leur mode d'application à cette problèmatique.

En comparaison des résultats (image de droite de la figure 5.1 page 89 et image (d) de la figure 4.6 page 78), les méthodes automatiques de classification s'avèrent presque aussi performantes que les méthodes de classification supervisées; les matières principales: fond, liquide céphalo-rachidien, substance grise et substance blanche, sont correctement reconnues.

En particulier, les méthodes de classification supervisées ne permettent pas de distinguer facilement différentes classes pour la substance grise ; pourtant par exemple, au regard des apprentissages manuels (tableau 2.5 page 52), le putamen et le noyau caudé ont des radiométries légèrement différentes. Nous ne pouvons donc pas attendre de méthodes de classification automatique qu'elles effectuent cette distinction supplémentaire.

Deux problèmes surviennent avec les algorithmes des k-moyennes et des c-moyennes floues :

- leur utilisation doit s'inscrire dans une procédure empirique afin de garantir que le résultat obtenu finalement soit proche du résultat optimal au sens de la fonction objectif (section 5.2.4),
- ces algorithmes ont tendance à imprimer aux résultats une forme standard des fonctions d'appartenance ou régions de décision au détriment des classes peu peuplées et des classes d'étalement radiométrique faible [CELE-89].

A propos de ce dernier problème, une variante semi-supervisée de l'algorithme des *c*-moyennes floues est proposée dans [PEDR-90] telle que la mise à jour des valeurs d'appartenance des points appris est due à moitié au terme de l'algorithme non supervisé et à moitié à l'information *a priori* de l'apprentissage. Cette variante améliore notablement la qualité de la classification finale, plus réaliste.

Cependant, nous lui avons préféré une méthode d'apprentissage de fonctions d'appartenance floue à partir de l'histogramme (section 5.4), dont les résultats sont tout aussi acceptables. Nous employons cette dernière méthode dans la partie suivante, en préliminaire à des segmentations morphologiques (section 7).

Les méthodes de classification exposées dans cette partie ont un inconvénient principal: elles n'introduisent aucune information contextuelle.

### **112** Deuxième partie

Si la classification n'est pas floue ou si la classification floue est « défuzzifiée », ces méthodes se limitent à un simple partitionnement de l'espace radiométrique de décision, et dans le cas d'une unique acquisition, cela revient à effectuer des seuillages de radiométrie. En conséquence, la cohérence spatiale des classes dans l'image n'est que partiellement respectée.

La partie III qui suit est dédiée à l'introduction d'informations contextuelles.

Dans la partie IV nous verrons que les méthodes de classifications de type k-moyennes peuvent être utilisées de façon beaucoup plus locales, dans des régions d'intérêt, ce qui élimine certains de leurs défauts. Troisième partie

# Segmentation contextuelle

# Introduction

A l'issue d'une classification non-contextuelle, nous connaissons les caractéristiques radiométriques des matières principales présentes dans les images cérébrales : l'air, le liquide céphalo-rachidien, la substance grise et la substance blanche. Cette connaissance a été acquise soit à l'aide d'un apprentissage supervisé (nous avons proposé à ce sujet un protocole robuste), soit après l'examen des classes données par une classification automatique. La segmentation résultante n'est pourtant pas toujours très satisfaisante; le fait de ne tenir compte d'aucune information de type contextuel est assez limitatif.

Nous pouvons considérer trois aspects distincts du contexte spatial d'un point : les connaissances associées aux points de son voisinage, sa localisation absolue dans l'image et sa localisation relative dans l'image.

Pour le premier aspect, considérer un point de l'image se résume à l'observation d'une toute petite région autour du point. Dans ce voisinage peuvent apparaître des informations de texture qui peuvent déterminer l'appartenance de ce point à une région particulière de l'image.

Pour le deuxième aspect, il s'agit de l'information de localisation d'un point au sein d'une région, ou par rapport à une ou plusieurs autres régions.

Pour le troisième aspect, un point est caractérisé à l'aide de connaissances *a priori* sur le contenu des images à traiter, à partir de sa seule position dans l'image. La prise en compte de cette information est délicate, car elle ne repose que sur des considérations d'ordre général sur les images, et peut mal s'accommoder des particularités d'une image donnée.

La partie III est dédiée à l'introduction des deux premiers types d'informations contextuelles. Les chapitres qui suivent s'articulent autour de ces notions, que nous proposons de traiter avec des formalismes mathématiques différents : sous forme de régularisation spatiale markovienne dans le chapitre 6, puis sous forme morphologique dans le chapitre 7; le chapitre 8 quant à lui, montre comment des estimations radiométriques précises peuvent être obtenues en dépit de la présence de voxels de mélange, grâce à un examen des interfaces entre structures.

# **Chapitre 6**

# Approche contextuelle par champs de Markov

Les méthodes non-contextuelles de classification examinées dans la partie II considèrent que l'appartenance d'un voxel à une classe ne dépend que de la radiométrie du voxel; aussi, les segmentations produites ne respectent pas toujours la cohérence spatiale des structures (Cf. le putamen dans la figure 4.6 page 78). Du fait du bruit et de la présence de volumes partiels, la loi statistique caractérisant la radiométrie d'une classe recouvre presque systématiquement la loi d'une ou de plusieurs autres classes (Cf. figure 4.2 page 71). L'application de seuils radiométriques pour décider de l'appartenance d'un voxel à une classe cause donc des erreurs, qui pourraient être évitées si des connaissances portées par le voisinage de ce voxel étaient prises en compte.

Dans ce chapitre, nous allons voir comment la prise en compte d'informations contextuelles peut intervenir dans la procédure de classification grâce aux méthodes fondées sur les champs de Markov. Ceux-ci, étudiés tout d'abord en mathématiques statistiques [BESA-74], ont fait leur apparition en traitement d'images pour résoudre des problèmes de restauration [GEMA-84]. Depuis, ils ont été utilisés en segmentation [DERI-87], en restauration [BESA-86], en reconstruction [BLAK-87] [DINT-90], en analyse et synthèse de textures [GEMA-87], en analyse de mouvements [BOUT-90] [DERO-95], en détection de contours [GEMA-90] [GEIG-91] [ZERU-93].

Après un rappel des principales notions sur les champs de Markov (section 6.1), nous présentons la forme des potentiels que nous utilisons (section 6.2), puis nous proposons ensuite deux méthodes de segmentation markovienne des volumes IRM du cerveau, l'une travaillant sur les voxels (section 6.3), et l'autre sur le graphe d'adjacence de régions obtenues par surface de partage des eaux 3D [GERA-95a] (section 6.4).

Les différents schémas de relaxation markovienne sont décrits en annexe B, avec une attention particulière sur les aspects algorithmiques de leur mise en œuvre sur des images de taille importante.

## 6.1 Problématique et notations

Le but de cette première section n'est pas de présenter trop formellement la théorie markovienne mais d'en donner un aperçu au travers d'un ensemble de notations que nous utilisons par la suite. Ces notations reprennent en partie celles qui sont définies dans le tableau 4.1 page 66 en partie II.

#### 6.1.1 Cadre topologique

Considérons l'image comme un ensemble de sites S. Chaque site s de S correspond à une localisation particulière dans l'image : ce peut être un voxel ou une région de l'image (dans ce dernier cas, les régions sont disjointes deux à deux).

Ajoutons une dimension topologique au problème en donnant à S une structure de graphe grâce à la définition pour chaque site s de son voisinage :

$$V_s = \{ s' \in S , s' \neq s \text{ et } s \in V_{s'} \}.$$

Ce graphe est un réseau régulier si S est l'ensemble des voxels d'une image, ou un graphe d'adjacence si S est un partitionnement de l'image en régions.

À la théorie des graphes nous empruntons la notion de clique, configuration de sites tous voisins deux à deux, ou le site lui-même.

Nous appellons *clique générique* un type de configuration<sup>1</sup>; une clique est alors une instance particulière d'une clique générique.

Prenons deux exemples. La configuration qui correspond au site unique est une clique générique ; une instance de cette dernière est une clique qui ne comprend qu'un site donné du graphe. La configuration qui est définie sur deux sites d'un réseau régulier 3D, tel que l'un d'eux a pour coordonnées relatives par rapport à l'autre (+0, -1, +1) dans ce réseau, est une seconde clique générique ; une instance de cette dernière est par exemple la clique { (3,3,3), (3,2,4) }.

L'ordre  $o_c$  d'une clique générique c est le nombre de sites dans la configuration qu'elle décrit. Nous noterons C l'ensemble des cliques génériques définies sur le graphe. Une clique générique  $c \in C$  se traduit généralement par plusieurs cliques sur le graphe S; notons  $l_c$  ce nombre de cliques :

$$c \to c^1, \dots, c^{l_c}$$
 avec  $c^l = \{ s^1(c^l), \dots, s^{o_c}(c^l) \},$ 

où  $s^q(c^l)$  est le  $q^{\text{ème}}$  site de la clique  $c^l$ . Classiquement, l'ordre d'une clique  $c^l$  est le nombre de sites qui la composent ; c'est donc  $o_c$ .

Une constatation importante est qu'un même site peut intervenir dans plusieurs cliques, ce qui s'écrit :

$$(l \neq l') \Rightarrow (\forall q \ \forall q' \ s^q(c^l) \neq s^{q'}(c^{l'})).$$

#### 6.1.2 Cadre probabiliste

Paramétrons par t l'ensemble des réalisations d'un phénomène aléatoire. Par la suite, t est interprété comme un paramètre temporel, toute réalisation particulière apparaissant à un instant donné.

Pour rester dans le cadre probabiliste, nous associons à chaque site s une variable aléatoire  $y_s$ . Pour un problème de classification, cette variable prend ses réalisations  $y_s^{(t)}$  dans l'ensemble  $\Omega$  des classes :

$$y_s^{(t)} \in \Omega \quad ext{avec} \quad \Omega = \{ \omega_1, \ldots, \omega_c \}.$$

<sup>1.</sup> Nous avons introduit cette notation, originale à notre connaissance, dans le but de formaliser avec un peu plus de précision certaines expressions.

Notons  $i_s(t)$  l'indice de la classe du site s dans la réalisation de paramètre t; il vient:  $y_s^{(t)} \in \omega_{i_s(t)}$ .

L'ensemble des variables aléatoires  $y_s$  associées aux sites  $s \in S$  forme un champ  $\mathcal{Y}$  de variables aléatoires :

$$\mathcal{Y} = \{ y_s \, , \, s \in S \} \, .$$

Une classification s'apparente à une réalisation  $Y^{(t)}$  du champ  $\mathcal{Y}$ :

$$Y^{(t)} = \{ y_s^{(t)}, s \in S \}.$$

Soit  $x_s$  la variable aléatoire représentant l'observation du site s. L'ensemble de ces variables forme sur S le champ des observations  $\mathcal{X}$ :

$$\mathcal{X} = \{x_s , s \in S\}.$$

La réalisation des observations qui nous intéresse tout particulièrement est l'image I à classifier, c'est-à-dire la réalisation telle que  $x_s$  ait pour valeur la radiométrie du site s, quel que soit  $s \in S$ ; notons  $x_s^I$  cette valeur.

Le lien avec les notations de la partie II est évident : l'ensemble des sites S de l'image I s'identifie à l'ensemble des individus X, et en posant que l'individu d'indice k dans X est le site s de S,  $x_s^I$ n'est autre que le vecteur caractéristique  $x_k$ . Nous pouvons écrire :

$$X = \{ x_s^I, s \in S \}.$$

#### 6.1.3 Cadre bayésien

Effectuer une classification bayésienne revient à maximiser la probabilité *a posteriori* (MAP en abrégé) :

$$p(\mathcal{Y} = Y^{(t)} | \mathcal{X} = X) = \frac{p(\mathcal{X} = X | \mathcal{Y} = Y^{(t)}) p(\mathcal{Y} = Y^{(t)})}{p(\mathcal{X} = X)}.$$

Or p(X = X), probabilité *a priori* de l'observation, est une constante du problème de classification ; seules les deux probabilités du produit suivant doivent être évaluées :

$$p(\mathcal{Y} = Y^{(t)} | \mathcal{X} = X) \propto p(\mathcal{X} = X | \mathcal{Y} = Y^{(t)}) p(\mathcal{Y} = Y^{(t)}), \qquad (6.1)$$

où  $\propto$  signifie « proportionnel à ».

Sous l'hypothèse que les observations en chaque site sont indépendantes les unes des autres, ce qui suppose implicitement que le bruit soit lui-aussi indépendant d'un site à l'autre, nous pouvons écrire :

$$p(\mathcal{X} = X | \mathcal{Y} = Y^{(t)}) = \prod_{s \in S} p(x_s = x_s^I | \mathcal{Y} = Y^{(t)}).$$
(6.2)

Cette hypothèse est raisonnable car, d'une part les images par résonance magnétique sont acquises puis reconstruites de telle façon que les données radiométriques obtenues pour un voxel ne sont pas (en première approximation) influencées par la proximité d'autres voxels, et d'autre part le bruit est considéré comme additif en chaque voxel et supposé gaussien (Cf. 2.3).

De plus, grâce à l'indépendance spatiale du bruit, la radiométrie en un site ne dépend que de la classe en ce site, d'où finalement :

$$p(\mathcal{X} = X | \mathcal{Y} = Y^{(t)}) = \prod_{s \in S} p(x_s = x_s^I | y_s = y_s^{(t)}).$$
(6.3)

Enfin, nous supposerons que la densité de probabilité conditionnelle  $p(x_s = x_s^I | y_s = y_s^{(t)})$  suit une loi gaussienne, ce que nous avons justifié dans la section 2.3.

Pour des facilités d'écriture qui apparaîtront par la suite, introduisons la fonction  $U^a$  vérifiant :

$$U^{a}(x_{s}^{I}, y_{s}^{(t)}) = -log(p(x_{s} = x_{s}^{I} | y_{s} = y_{s}^{(t)}));$$
(6.4)

remarquons qu'elle n'est définie que si la densité de probabilité conditionnelle n'est jamais nulle.

Dans le cas de données monodimensionnelles,  $U^a$  s'écrit :

$$U^{a}(x_{s}^{I}, y_{s}^{(t)}) = \frac{(x_{s}^{I} - v_{i_{s}(t)})^{2}}{2 \sigma_{i_{s}(t)}^{2}} + \log(\sqrt{2\pi} \sigma_{i_{s}(t)}).$$
(6.5)

Afin de mener à bien la classification, il nous reste encore à déterminer la loi de probabilité globale  $p(\mathcal{Y} = Y^{(t)})$ , qui malheureusement ne peut pas être calculée directement.

#### 6.1.4 Cadre markovien

L'hypothèse markovienne suppose que la probabilité de réalisation d'un site conditionnellement à la réalisation des autres sites du graphe ne dépend que de la réalisation sur le voisinage du site considéré. Notons  $\mathcal{Y} - \{y_s\}$  le champ  $\mathcal{Y}$  privé de sa variable aléatoire  $y_s$ , et  $\mathcal{Y}_{V_s}$  la restriction du champ  $\mathcal{Y}$  aux variables aléatoires définies pour les sites du voisinage  $V_s$  du site s. L'hypothèse markovienne s'écrit :

$$p(y_s = y_s^{(t)} | \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\}) = p(y_s = y_s^{(t)} | \mathcal{Y}_{V_s} = Y_{V_s}^{(t)}).$$
(6.6)

On dit alors que le champ  $\mathcal{Y}$  de variables aléatoires est un champ de Markov.

Le théorème de Hammersley-Clifford [BESA-74] permet alors d'accéder à la loi de probabilité globale d'une réalisation : si aucune réalisation d'un champ de Markov  $\mathcal{Y}$  n'est de probabilité nulle, la probabilité globale d'une réalisation de ce champ suit une loi de probabilité de Gibbs. Ainsi :

$$p(\mathcal{Y} = Y^{(t)}) = \frac{e^{-U(Y^{(t)})}}{Z},$$
 (6.7)

où Z (fonction de partition) est une constante de normalisation sur l'ensemble des réalisations de  $\mathcal{Y}$ .

Il nous faut maintenant formaliser l'expression de  $U(Y^{(t)})$ , qui s'interprète comme une énergie en physique statistique, domaine dont ces équations sont issues.

#### 6.1.5 Cadre énergétique

Afin de quantifier les propriétés d'un graphe, nous pouvons introduire une fonction de potentiel  $U_c(Y^{(t)})$ , associée à chaque clique générique c et appliquable à toute réalisation  $Y^{(t)}$ . Cette fonction est la somme des potentiels des cliques instances de c:

$$U_c(Y^{(t)}) = \sum_{l=1}^{l_c} U_{cl}(Y^{(t)}).$$

Chacun de ces potentiels met en relation différents descripteurs des sites composant la clique  $c^l$ . Un potentiel de clique  $U_{c^l}(Y^{(t)})$  s'exprime généralement par une fonction  $f_c$ , dont l'expression dépend de la clique générique c considérée. La valeur de cette fonction varie suivant la clique  $c^l$  et l'état des sites qui la compose ; soit :

$$U_{c^{l}}(Y^{(t)}) = f_{c}\left(y_{s^{1}(c^{l})}^{(t)}, \ldots, y_{s^{o_{c}}(c^{l})}^{(t)}\right) \,.$$

L'énergie globale du graphe  $U(Y^{(t)})$  est la somme des fonctions de potentiel de chaque clique :

$$U(Y^{(t)}) = \sum_{c \in C} U_c(Y^{(t)}) = \sum_{c \in C} \sum_{l=1}^{l_c} U_{c^l}(Y^{(t)}).$$

La plupart des travaux s'arrêtent à cette expression globale de l'énergie; ici, nous proposons de caractériser l'énergie en chaque site, ce qui pourrait servir, par exemple, à dresser une cartographie énergétique d'un graphe (ou d'une image).

À l'échelle d'un site s, nous pouvons aussi définir une énergie locale par la somme pondérée de toutes les fonctions de potentiel auxquelles le site participe :

$$U_{s}(Y^{(t)}) = \sum_{c \in C} \left( \frac{1}{o_{c}} \sum_{l=1..l_{c}, s \in c^{l}} U_{c^{l}}(Y^{(t)}) \right).$$
(6.8)

La division par  $o_c$  s'explique par le fait que le potentiel  $U_{c^l}(Y^{(t)})$  va intervenir dans le calcul les énergies locales  $U_{s^1(c^l)}(Y^{(t)}), \ldots, U_{s^{o_c}(c^l)}(Y^{(t)})$ , soit  $o_c$  fois ; après division, sa contribution globale à l'ensemble des sites (Cf. équation (6.9)) est donc unitaire.

La contrainte  $s \in c^l$  restreint au simple voisinage de s la connaissance de  $Y^{(t)}$  nécessaire au calcul de  $U_s(Y^{(t)})$ ; nous pouvons traduire cela par l'écriture :

$$U_s(Y^{(t)}) = U_s(Y^{(t)}_{V_s}).$$

Nous retrouvons ici le pendant, en termes d'énergies, de l'hypothèse probabiliste markovienne (6.6).

L'énergie locale en *s* s'interprète comme la participation du site *s* à l'énergie globale :

$$U(Y^{(t)}) = \sum_{s \in S} U_s(Y^{(t)}_{V_s}), \qquad (6.9)$$

égalité qui traduit l'interdépendance des sites.

#### 6.1.6 Cadre local

Cette dernière écriture nous permet de replacer le problème dans un cadre local; en effet, en reportant dans (6.1) les expressions (6.3) et (6.7), puis (6.4) et (6.9), il vient:

$$p(\mathcal{Y} = Y^{(t)} | \mathcal{X} = X) \propto \exp\left(-\sum_{s \in S} \left( U^a(x_s^I, y_s^{(t)}) + U_s(Y_{V_s}^{(t)}) \right) \right).$$

La maximisation de la probabilité globale revient à minimiser l'énergie globale :

$$\sum_{s \in S} \left( U^a(x_s^I, y_s^{(t)}) + U_s(Y_{V_s}^{(t)}) \right) , \qquad (6.10)$$

somme des énergies locales de chaque site. Cette dernière est composée de deux termes : le premier caractérise l'attache aux données de ce site et le second, terme contextuel, l'influence du voisinage du site.

Nous pouvons en déduire une écriture de la probabilité (locale) qu'un site soit dans tel état connaissant l'état des autres sites :

$$p(y_s = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\}) = \frac{1}{Z_s^{(t)}} exp\left(-U^a(x_s^I, y_s^{(t)}) - U_s(Y_{V_s}^{(t)})\right),$$
(6.11)

avec  $Z_s^{(t)}$  coefficient normalisateur des probabilités locales en s pour la réalisation Y(t).

C'est cette probabilité que nous allons utiliser dans les algorithmes d'optimisation que nous présentons dans la section suivante.

#### 6.1.7 Originalité markovienne

Avant de présenter les algorithmes d'optimisation, situons les méthodes markoviennes dans la panoplie des méthodes de classification.

Au cours de la partie II, nous avons considéré qu'un site est classifié uniquement à partir de la valeur observée en ce site, sa radiométrie. Aucune notion de contexte n'intervient; la classification est dite aveugle (Cf. figure 6.1). Elle se traduit par l'égalité :

$$p(y_s = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\}) = p(y_s = y_s^{(t)} | x_s = x_s^I).$$

Pour induire une régularisation contextuelle, il est nécessaire que la classification d'un site prenne en compte les observations sur le voisinage de ce site (Cf. figures 6.3 et 6.4). La classification se traduit par une des deux égalités suivantes :

$$p(y_s = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\}) = p(y_s = y_s^{(t)} | \mathcal{X}_{V_s} = X_{V_s}),$$

ou

$$p(y_s = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\}) = p(y_s = y_s^{(t)} | \mathcal{X}_{V_s} = X_{V_s}, x_s = x_s^I).$$

Notons que la première égalité, contrairement à la seconde, n'est pas une extension de la classification aveugle; en effet, un site n'appartenant pas à son voisinage, la valeur observée en ce site n'intervient pas pour sa propre classification (dit autrement, il n'y a aucune relation formelle entre  $X_{V_s}$  et  $x_s^I$ ). Néanmoins, la valeur observée en un site et l'ensemble des valeurs observées dans son voisinage sont empiriquement corrélées. Appuyer la classification d'un site par l'examen de son voisinage plutôt que de se restreindre au site seul met donc à profit plus d'informations, et permet souvent de s'affranchir d'erreurs locales à un site.

Notons enfin que la classe d'un site ne dépend toujours pas de celles de ses voisins; la classification reste encore locale.

Une troisième politique d'étiquetage est la méthode markovienne que nous venons de décrire. La classification d'un site dépend de l'observation en ce site (premier terme de l'équation (6.11)) et des classes de ses sites voisins (second terme) :

$$p(y_s = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\}) = p(y_s = y_s^{(t)} | x_s = x_s^I, \mathcal{Y}_{V_s} = Y_{V_s}^{(t)})$$

Cette formulation est récurrente à deux niveaux : la classification d'un site dépend de la classification globale de l'image et donc, s'appuie sur l'observation de l'image tout entière (Cf. figures 6.5 et 6.6). Les méthodes markoviennes sont globales.

Enfin, signalons l'existence de deux autres méthodes globales dont les résultats sont théoriquement équivalents à ceux du MAP (en pratique, les estimations et les méthodes d'échantillonnage ne sont pas les mêmes que pour le MAP; aussi les résultats ne sont jamais rigoureusement les mêmes) : le *Maximum Posterior Marginal* et le *Threshold Posterior Mean* [MARR-87] [PARI-88] [GEIG-91]. Ces méthodes introduisent chacune une fonction de perte nécessitant, en théorie, une sommation sur l'ensemble des configurations possibles Y; cette fonction est souvent approchée par une technique du type champs moyens.

Pour toutes ces raisons, nous avons opté pour la mise en œuvre de la maximisation de la probabilité *a posteriori*.

### 6.2 Forme des fonctions de potentiel

Les premiers exemples de champ de Markov parus dans la littérature consacrée au traitement d'images possédaient tous un certain nombre de caractéristiques communes : les images à segmenter sont binaires ou à niveaux de gris, la connexité est 4 ou 8, seules les cliques d'ordre 2 sont utilisées, les fonctions de potentiel sont en tout ou rien. Depuis, l'évolution de la recherche sur les champs de Markov nous permet d'employer des modélisations variées et plus fines, et en particulier, dédiées à la spécificité des images tridimensionnelles que nous manipulons.

#### 6.2.1 Modèle de Potts

Le modèle de Potts est une généralisation, à un nombre quelconque d'états, du modèle d'Ising, utilisé pour l'étude des champs de spins en physique statistique. Le succès de son application au domaine du traitement d'images provient du fait qu'il permet d'appréhender relativement simplement les phénomènes liés aux modélisations markoviennes [DESC-93] [SIGE-93].

Le modèle de Potts considère uniquement les cliques d'ordre 2 et les fonctions de potentiel associées prennent la forme :

$$f_{c^{2}}\left(y_{s}^{(t)}, y_{s'}^{(t)}\right) = -\beta_{i_{s}(t)}^{\text{Potts}} \delta\left(y_{s}^{(t)}, y_{s'}^{(t)}\right)$$

avec  $\delta$  symbole de Kronecker, et  $\beta_{i_s(t)}^{\text{Potts}}$  potentiel de Potts.

Afin d'obtenir une véritable segmentation, la création de régions (ensemble spatialement cohérent de sites de même état ou classe) doit être favorisée. On prend donc des valeurs de  $\beta$  positives pour que ce potentiel soit attractif, cette tendance étant d'autant plus forte que les  $\beta$  ont une valeur élevée.

Remarquons que l'ensemble des fonctions de potentiel est défini à une constante près ce qui ne modifie pas le problème d'optimisation (et ce qui permet de retrouver le modèle d'Ising lorsque les classes sont au nombre de deux).

Le terme d'énergie contextuelle étant négatif à l'intérieur de toute région, l'augmentation de l'énergie contextuelle globale de l'image est due uniquement à l'existence de frontières entre régions. Minimiser cette énergie se traduit par une réduction de la quantité de frontières : la formation de petites régions est défavorisée et le contour des régions tend à être lisse. On parle de régularisation markovienne.

Si nous n'avions pas de terme d'énergie d'attache aux données, les frontières disparaîtraient : une classe particulière prendrait le dessus sur les autres et formerait une région unique recouvrant toute l'image. Le réglage de l'influence respective des deux termes énergétiques est donc essentiel puisque la force de régularisation désirée dépend de lui.

#### 6.2.2 Matrice de Potts

Le modèle de Potts peut être facilement étendu par la définition d'une matrice B que nous appellerons, par abus de langage, matrice de Potts :

$$B = \left[ \beta_{i,j} \right]_{i=1...c}, j=1...c$$

La valeur de  $\beta_{i,j}$  caractérise, si elle est positive, l'attraction entre deux sites voisins d'états respectifs i et j; si la valeur de  $\beta_{i,j}$  est négative, sa valeur absolue caractérise la répulsion.

La symétrie des potentiels n'impose qu'une contrainte unique :

$$\beta_{j,i} = \beta_{i,j} \quad \forall i \; \forall j \; ,$$

et les potentiels ont la forme suivante :

$$f_{c^2}\left(y_s^{(t)}, y_{s'}^{(t)}\right) = -\beta_{i_s(t), i_{s'}(t)}.$$
(6.12)

Le modèle de Potts classique correspond alors aux cas particuliers des matrices diagonales :

$$egin{aligned} eta_{i,j} &= 0 & \forall j 
eq i \ eta_{i,i} &= eta_i^{ ext{Potts}} & \forall i ; \end{aligned}$$

les éléments non diagonaux de la matrice B sont donc les nouveaux paramètres de la modélisation.

Citons par exemple [VAND-93] où les potentiels sont donnés par :

$$f_{c^2}\left(y_s^{(t)}, y_{s'}^{(t)}\right) = \begin{cases} -1 & \text{si } y_s^{(t)} = y_{s'}^{(t)} \\ 0 & \text{si } y_s^{(t)} \text{ et } y_{s'}^{(t)} \text{ sont compatibles} \\ 20 & \text{si } y_s^{(t)} \text{ et } y_{s'}^{(t)} \text{ sont incompatibles.} \end{cases}$$

La compatibilité entre deux classes signifie qu'une région d'une classe peut être voisine dans l'image d'une région de l'autre classe. Les frontières entre deux classes incompatibles ont une énergie élevée ; leur existence est donc très défavorisée.

Si aucune connaissance du contenu de l'image à classifier n'est disponible, la matrice de Potts n'est pas fixée *a priori*. Dans [DERI-87] et [LAKS-89], il est montré comment mener l'estimation des paramètres des potentiels de cliques durant la procédure de relaxation (en fait, après chaque tour; voir plus loin la définition d'un tour). Dans ces études, les paramètres des classes sont supposés acquis.

Dans le cas contraire, les valeurs des potentiels peuvent être précalculées en fonction de toutes les combinaisons possibles d'états. Ainsi, ce calcul n'est effectué qu'une seule fois au lieu d'être répété intensivement (et donc de façon extrêmement redondante) lors de la procédure de relaxation.

#### Autres modèles

D'autres formes de fonctions de potentiel ont été proposées afin de prendre en compte moins brutalement les interactions entre régions, par exemple :

$$V_c(y_s^{(t)}, y_{s'}^{(t)}) = rac{1}{1 + rac{|y_{s'}^{(t)} - y_s^{(t)}|}{1 + rac{|y_{s'}^{(t)} - y_s^{(t)}|}{2}}}$$
 ou  $V_c(y_s^{(t)}, y_{s'}^{(t)}) = |y_{s'}^{(t)} - y_s^{(t)}|^n$ 

Le lecteur désireux de plus amples informations pourra se reporter aux thèses [DESC-93] et [SIGE-93].

#### 6.2.3 Matrice de Potts 3D

Le cas particulier d'images tridimensionnelles, la plupart du temps anisotropes, nécessite de reconsidérer la valeur des potentiels.

Afin de différencier parmi les cliques d'ordre 2, celles qui sont formées de voxels partageant une face, de celles qui sont formées de voxels partageant une arête, dans [YAN-95] les potentiels sont définis suivant :

$$f_c(y_s(t), y_{s'}(t)) = \begin{cases} 0 & \text{si } y_s(t) = y_{s'}(t) \\ \beta & \text{si } y_s(t) \neq y_{s'}(t) \text{ et si } s \text{ et } s' \text{ partagent une face} \\ \beta/\sqrt{2} & \text{si } y_s(t) \neq y_{s'}(t) \text{ et si } s \text{ et } s' \text{ partagent une arête.} \end{cases}$$

Nous pouvons généraliser cette idée aux images anisotropes ainsi qu'au modèle de Potts étendu. Considérons un site s et un de ses sites voisins s', en reprenant la formulation (6.12), il vient :

$$f_{c^2}\left(y_s^{(t)}, y_{s'}^{(t)}\right) = -\frac{\beta_{i_s(t), i_{s'}(t)}}{d\left(y_s^{(t)}, y_{s'}^{(t)}\right)},$$

avec d fonction distance.

Nous pouvons remarquer que nous ne distinguons pas ici l'orientation des cliques d'ordre 2 par l'emploi de fonctions de potentiel de formes différentes; cela traduit en fait la volonté de ne pas privilégier de direction particulière dans l'image 3D.

#### 6.2.4 Cliques d'ordre 1

Une dernière remarque concerne la prise en compte éventuelle des cliques d'ordre 1 (qui ne font pas partie du modèle de Potts).

Une première idée est d'ajouter le potentiel :

$$f_{c^1}(y_s^{(t)}) = -\alpha_{i_s^{(t)}},$$

où une forte valeur de  $\alpha_i$  favorise l'affectation de la classe  $\omega_i$  indépendamment du site considéré. C'est donc un excellent moyen d'introduire la probabilité *a priori* de chaque classe ; ce terme permet en effet d'effectuer une analogie entre l'expression du classifieur bayésien (4.3) page 71 et celle de l'énergie (6.5) page 120. Il suffit de poser :

$$\alpha_{i_s^{(t)}} = P(\omega_{i_s^{(t)}}) \,.$$

Lorsque la classification est bayésienne mais non contextuelle, nous avons vu en section 4.3.2 que l'introduction de la probabilité *a priori* des classes ne produit pas de différences significatives (figure 4.3 page 73). En revanche, dans le cas d'une classification markovienne, son emploi, tel que nous venons de l'exprimer, peut avoir une influence désastreuse sur les résultats finals. En effet, la classe qui serait défavorisée par le potentiel *a priori* est celle du liquide céphalo-rachidien, bien moins représenté dans l'image que ne le sont les substances grise et blanche; cette pénalisation va donc dans le sens de la régularisation contextuelle, qui a tendance à effacer, comme nous le verrons, les sillons trop fins.

Une seconde idée, utilisée dans [KARS-90] pour la segmentation de la rate dans des tomographies 3D, peut être d'introduire des informations *a priori* sur la localisation spatiale des classes à l'aide de :

$$f_{c^1}(y_s^{(t)}) = -\phi_{i_s^{(t)}}(s) , \qquad (6.13)$$

où une forte valeur de  $\phi_i(s)$  favorise l'affectation au site *s* de la classe  $\omega_i$ , la seule contrainte étant de n'interdire aucune configuration (Cf. théorème de Hammersley-Clifford en section 6.1.4), donc ne pas prendre de potentiels infinis. Les  $\phi_i$  s'apparentent à des cartes de localisation de structures que l'on trouve dans des atlas probabilistes (voir plus loin en fin de section 9.1.2).

Pour qu'une prise en compte d'informations *a priori* de localisation soit pertinente, il est indispensable, à cause de la variabilité du positionnement de la tête dans les acquisitions IRM, d'effectuer une mise en correspondance au préalable de ces informations avec l'image particulière à traiter.

### 6.3 Site voxélique

En traitement d'images par champ de Markov, une première approche est de construire un graphe à partir de la topologie de l'image : chaque site du graphe s'identifie à un point de l'image, et les notions de voisinage définies sur le graphe sont celles qui existent sur le maillage de l'image. Cette section se limite à cette approche et ne traite donc que des classifications contextuelles sur les voxels.

#### 6.3.1 État de l'art

Les techniques markoviennes ont été appliquées à de nombreuses reprises au problème de la segmentation des structures cérébrales en IRM avec une approche « voxel »; nous présentons ici quelques adaptations intéressantes de ces techniques.

#### Modèle du mixel

Dans [CHOI-91], la relaxation markovienne est considérée comme une solution au problème de classification des volumes partiels. Le mélange constituant tout voxel peut être formalisé par un vecteur de variables aléatoires appelé mixel :

$$x_s = \{x_{s1}, \ldots, x_{sm}\},\$$

où la variable  $x_{si}$  correspond à la contribution au site s de la  $i^{\text{ème}}$  matière, dans une classification en m classes ; naturellement :

$$\sum_{i=1}^{m} x_{si} = 1.$$

La sémantique employée pour  $x_s$  n'est donc pas celle que nous avons décrite précédemment ; une réalisation de X donne pour chaque site le vecteur de sa composition. Classiquement, la loi radiométrique de chaque matière est supposée gaussienne (multigaussienne si les acquisitions sont multiples), et la radiométrie d'un voxel est supposée linéaire en fonction de son mixel et des lois radiométriques des matières.

L'inconvénient majeur de cette formulation réside dans la contrainte théorique de devoir disposer de m - 1 acquisitions pour pouvoir calculer la composition des voxels en fonction des m matières. Les auteurs proposent alors de modifier tout mixel pour que les deux (ou trois) matières qui y sont les plus représentées soient finalement les seules à avoir une contribution  $x_{si}$  non nulle. En dépit de cette modification, la résolution markovienne est très lente, malgré un recours à l'algorithme des modes conditionnels itérés (annexe B.2.3).

Sur les images de l'article, les résultats finals sont corrects, ce qui explique que cette méthode a été largement reprise en imagerie médicale [SANT-93] [FESS-94] [LIAN-94] [WANG-94a] [LI-95].

Une variante de cette méthode est proposée dans [JAGG-97], appliquée à la segmentation des matières cérébrales principales (liquide céphalo-rachidien, substance grise, et substance blanche); elle comporte deux étapes de classification markovienne. La première consiste à introduire deux nouvelles classes pour caractériser les voxels de mélange du liquide céphalo-rachidien avec la substance grise, et de la substance grise avec la substance blanche. La seconde étape évalue le mélange des voxels de ces deux dernières classes avec le modèle du mixel.

Cette variante, très récente, offre trois avantages :

- la complexité de l'optimisation markovienne du modèle du mixel est réduite,

- la classe de mélange du liquide céphalo-rachidien avec la substance grise assure la cohérence spatiale des sillons corticaux, ce qui évite leur disparition avec la relaxation,
- la considération explicite de classes de mélange permet d'éviter que les voxels de mélange de deux classes soient affectés à une tierce classe (comme c'est le cas sur l'image de gauche de la figure 6.9 page 140).

#### Estimation des caractéristiques des classes

Jusqu'à présent, nous avons mentionné le terme d'attache aux données sans le développer; nous avons réaffirmé que nous le supposions gaussien (ou multigaussien) mais nous n'avons pas précisé si nous connaissions ses caractéristiques pour les différentes classes.

Si ses caractéristiques sont inconnues parce qu'aucun apprentissage n'a eu lieu, elles doivent être évaluées au cours de la relaxation. Cette tâche s'apparente à celle que réalisent les méthodes automatiques de classification dont nous avons parlé dans la partie II ; nous pouvons employer le même procédé : après chaque itération, les caractéristiques d'une classe  $\omega_i$  sont évaluées avec l'ensemble des individus attribués à cette classe, soit  $\{s \mid i_s(t) = i\}$ .

Dans [PAPP-92] les caractéristiques des classes sont supposées hétérogènes dans l'image et une méthode particulière est présentée pour réaliser leur estimation.

Avant de procéder à la relaxation, l'algorithme des k-moyennes est utilisé pour obtenir une approximation, globale sur l'image, des caractéristiques des classes. Puis, à chaque itération, ces caractéristiques sont calculées en chaque site à l'aide d'une fenêtre centrée sur ce site (pour une classe donnée, l'estimation prend en compte uniquement les sites affectés à cette classe et pris dans la fenêtre). Les caractéristiques obtenues sont donc locales; mieux, elles sont continues d'un site à un site voisin de par le recouvrement de leurs fenêtres respectives.

La taille de la fenêtre décroît au cours de la relaxation : au début, elle recouvre toute l'image puis, à certains moments, voit ses dimensions divisées par deux jusqu'à atteindre un volume minimal garantissant des statistiques fiables. Ainsi, les caractéristiques deviennent de plus en plus locales.

Cette méthode est séduisante lorsque l'on souhaite prendre en compte l'hétérogénéité éventuelle de la radiométrie de l'image ; elle est mise en pratique dans [VEIJ-94]. Les IRM 3D que nous devons traiter ayant une radiométrie bien homogène, nous n'avons pas implanté cette méthode.

Lors de la mise en œuvre de méthodes markoviennes, nous considérerons que les caractéristiques des classes sont connues (elles sont portées sur le tableau 2.5). Ainsi, nous pourrons mieux apprécier sur les résultats obtenus l'influence des différences algorithmiques de ces méthodes.

#### 6.3.2 Comparaison de classifications contextuelles

Nous avons comparé sur une même image  $(xavT_1)$  les résultats obtenus par différentes approches.

L'attache aux données est telle qu'elle est définie par l'expression (6.5); elle correspond pour chaque classe à une loi radiométrique gaussienne. Les paramètres des différentes lois sont ceux qui ont été appris en partie I et qui ont été déjà utilisés pour la classification bayésienne supervisée en partie II.

#### **Classifications non markoviennes**

La figure 6.1 ne tient compte que de l'attache aux données : c'est une classification bayésienne où les classes sont supposées équiprobables et les probabilités conditionnelles gaussiennes et connues.

Le manque de régularisation se manifeste par des nuages de voxels isolés, classifiés différemment de la région dans laquelle ils se situent.

Un traitement par filtrage majoritaire, illustré en figure 6.2, corrige partiellement ce défaut mais en en faisant apparaître d'autres. En effet, des structures trop fines sont effacées partiellement : c'est le cas des sillons, des interstices de substance blanche situés entre les circonvolutions corticales, des capsules blanches, du liquide céphalo-rachidien de l'enveloppe cérébrale ; de plus, les petits amas de classe air/os n'ont pas disparu des ventricules. Cette voie ne donne donc pas de résultats exploitables.

Les figures 6.3 et 6.4 permettent d'apprécier l'intérêt des classifications contextuelles locales (la classe d'un voxel repose sur l'observation de son voisinage). La première utilise une régularisation par filtrage par la moyenne, et la seconde par la médiane ; les deux résultats observés sont très similaires, et en tout cas bien meilleurs que ceux des deux approches précédentes.

En comparaison avec la régularisation par la médiane, la régularisation par la moyenne fournit une bonne segmentation des ventricules et préserve correctement les capsules blanches (cruciales pour séparer par la suite le putamen et le cortex); en revanche, elle efface une plus grande partie des sillons et détruit par endroits la structure crânienne.

#### Classifications markoviennes sans potentiels de localisation

Une méthode de relaxation markovienne avec recuit simulé (température initiale  $T_0 = 100$  et coefficient de décroissance géométrique de la température  $c_T = 0,99$ ) donne, quant à elle, une segmentation plus fidèle à nos attentes; voir la figure 6.5. Les défauts des méthodes précédentes s'estompent mis à part la disparition partielle des sillons; ces derniers sont trop fins pour que la prise en compte d'informations contextuelles joue en leur faveur.

Pour l'exécution de la relaxation, nous n'avons fait intervenir que les cliques d'ordre deux par l'entremise d'une matrice de Potts portée sur le tableau 6.1; en un site, nous nous sommes limités aux six réalisations de cliques d'ordre deux correspondant aux voisins du site en 6-connexité. Les potentiels ont été fixés empiriquement après que nous avons constaté la très fidèle reproductivité des résultats, lorsque les potentiels d'intérieur de régions (-1) et de frontières compatibles (0) conservent le même ordre de grandeur, et lorsque les potentiels de répulsion (ici 1 et 2) sont plus élevés.

	AIR	LCR	SBR	SBL
AIR	-1	0	1	2
LCR	0	-1	0	1
SBR	1	0	-1	0
SBL	2	1	0	-1

TAB. 6.1 – Matrice de Potts pour la segmentation du cerveau en 4 classes

En notant  $V_s^6$  le 6-voisinage, l'équation (6.8) est donc appliquée sous la forme :

$$U_s(X^{(t)}) = \frac{1}{2} \sum_{s' \in V_s^6} f_{c^2} \left( x_s^{(t)}, x_{s'}^{(t)} \right)$$
(6.14)

avec  $f_{c^2}$  calculé à partir de la matrice de Potts (tableau 6.1) suivant la formule (6.12).

Le seul point délicat consiste en fait à respecter l'équilibre entre le terme d'attache aux données et le terme contextuel afin de régler la force de la régularisation. Elle ne doit être ni trop faible, au risque de retrouver les défauts des méthodes non-contextuelles, ni trop forte, au risque de voir disparaître les structures peu volumineuses du cerveau. Nous avons finalement pondéré par 0,75 le

terme d'énergie d'attache aux données. Ce paramètre s'est avéré robuste d'une acquisition IRM à l'autre et les résultats de la relaxation restent constants tant que ce paramètre conserve cet ordre de grandeur (le multiplier ou le diviser par un facteur 2 commence à modifier l'aspect des résultats).

L'inconvénient majeur d'une relaxation markovienne reste sa très grande lenteur, même après l'introduction d'un recuit. Une solution généralement employée provient de l'algorithme des modes conditionnels itérés. Du fait de la faible amplitude des énergies d'attache aux données et de contexte, le paysage énergétique des réalisations est bien nivelé et régulier, et aucun minimum d'énergie globale n'est rencontré en dehors de la proximité de la réalisation recherchée. Cela reste vrai y compris lorsque l'initialisation est aléatoire ; en effet, sur les images qui nous ont servi de tests, l'algorithme des modes conditionnels itérés n'a jamais nécessité une initialisation proche de la solution désirée.

En particulier, les résultats de la descente, montrés en figure 6.6 sont similaires à ceux d'un recuit; nous privilégierons donc cette démarche, qui nous fournit un résultat en 5 minutes, au lieu de 3/4 d'heure pour un recuit.

#### Classifications markoviennes avec potentiels de localisation

Pour finir, nous avons introduit des potentiels de localisation spatiale (Cf. section 6.2.4 formule (6.13)). Leur but est d'influer sur l'affectation d'un voxel à une classe en fonction de la position de ce voxel dans l'image.

Pour distinguer le cortex et les noyaux centraux, nous nous appuyons sur les connaissances *a priori* suivantes : par rapport au cerveau, le cortex est périphérique, tandis que les noyaux centraux sont bien à l'intérieur. Ces deux classes sont dotées d'une fonction de potentiel de localisation ; pour les autres classes (fond, liquide céphalo-rachidien, et substance blanche), nous considérons que leurs fonctions de potentiel de localisation est nulle.

A partir d'une segmentation du cerveau (voir la description de la méthode en section 7.2), nous effectuons sur le masque binaire du cerveau une fermeture morphologique de 2 cm, puis nous calculons dans ce masque fermé une carte D de distance à sa surface, par propagation d'un chanfrein [BORG-86]; enfin, nous construisons une image par fonction de potentiel de localisation: l'image  $P_{CTX}$  pour le cortex (figure 6.7), et l'image  $P_{NCE}$  pour les noyaux (figure 6.8). Ces images se déduisent de D suivant:

$$P_{CTX}(x, y, z) = \begin{cases} 0 & \text{si } D(x, y, z) \leq \frac{D_{max}}{2} \\ (D(x, y, z) - \frac{D_{max}}{2}) \times \varphi & \text{si } D(x, y, z) > \frac{D_{max}}{2} \end{cases}$$
$$P_{NCE}(x, y, z) = \begin{cases} \left(\frac{D_{max}}{2} - D(x, y, z)\right) \times \varphi & \text{si } D(x, y, z) \leq \frac{D_{max}}{2} \\ 0 & \text{si } D(x, y, z) > \frac{D_{max}}{2} \end{cases}$$

où  $\varphi$  est une constante, et  $D_{max}$  la distance maximale de D.

Ces définitions de potentiels (positifs) défavorisent la présence de voxels étiquetés cortex lorsque ces derniers se rapprochent trop du centre du cerveau, et la présence de voxels étiquetés noyaux lorsque ces seconds se rapprochent trop de la périphérie du cerveau.

Nous présentons de nouveau sur l'image  $x av T_1$ , les résultats de la relaxation markovienne. Nous conservons les termes d'énergie d'attache aux données, déduits de modèles gaussiens (leurs paramètres sont indiqués par le tableau 2.5 page 52). En revanche, nous étendons la matrice de Potts, donnée précédemment par le tableau 6.1), pour qu'elle prenne en compte les cinq classes considérées ; cette nouvelle matrice est donnée par le tableau 6.2. Enfin, pour que les valeurs de potentiel de localisation ne soient pas trop disproportionnées par rapport aux autres termes énergétiques, et



FIG. 6.1 – Segmentation de  $xavT_1$  par classification non-contextuelle

Cette planche de coupes axiales de la segmentation de  $xavT_1$  a été produite avec une méthode bayésienne non contextuelle; la probabilité locale s'identifie à  $p(y_s | x_s^I)$  en notation abrégée. Les quatre classes sont : le fond (en blanc), le liquide céphalorachidien (en noir), la substance grise (en gris foncé), et la substance blanche (en gris clair).



FIG. 6.2 – Segmentation de  $xavT_1$  par filtrage majoritaire d'une classification non-contextuelle

Cette planche de coupes axiales de la segmentation de  $xavT_1$  est issue d'un filtrage majoritaire appliqué à la segmentation 3D montrée sur la planche de la figure 6.1; si les nuages de voxels isolés ont disparu, certaines structures trop fines ont été gommées (c'est le cas d'une partie importante des sillons corticaux).



FIG. 6.3 – Segmentation contextuelle de  $xavT_1$  par classification locale sur la moyenne

Cette planche de coupes axiales de la segmentation de  $xavT_1$  provient d'une classification contextuelle locale utilisant un filtre moyenneur ; la régularisation se traduit par la probabilité locale  $p(y_s \mid \text{moyenne} \{ x_{s'}^I, s' \in V_s \})$  en notation abrégée.



FIG. 6.4 – Segmentation contextuelle de  $xavT_1$  par classification locale sur le médian

Cette planche de coupes axiales de la segmentation de  $xavT_1$  provient d'une classification contextuelle locale utilisant un filtre médian (en remplacement du filtre moyenneur de la figure 6.3); la probabilité locale est  $p(y_s | \text{médian} \{ x_{s'}^I, s' \in V_s \})$  en notation abrégée.


FIG. 6.5 – Segmentation de  $xavT_1$  par classification markovienne avec recuit simulé

Cette planche de coupes axiales correspond à la classification markovienne de  $xavT_1$  avec recuit markovien ( $T_0 = 100, c_T = 0,99$ ); l'algorithme utilisé est celui de Métropolis (section B.2.2), et a nécessité un peu plus de 700 itérations, soit environ 3/4 d'heure sur une machine puissante.



FIG. 6.6 – Segmentation de  $xavT_1$  par classification markovienne par ICM

Cette planche de coupes axiales est, tout comme celle de la figure 6.5, tirée d'une classification markovienne de  $xavT_1$ , mais cette fois avec l'algorithme des modes conditionnels itérés ; la convergence a été atteinte en 8 itérations et le temps de calcul nécessaire n'a pas dépassé 5 minutes.



FIG. 6.7 – Planche de l'image de la fonction de potentiel  $\phi_{CTX}$  de localisation spatiale

Le calcul de l'énergie d'un voxel étiqueté cortex fait intervenir un terme additionnel donné par le voxel correspondant dans cette image de potentiel; cette image, construite à partir d'une carte de distance à la surface du cerveau (fermé de 2 cm), défavorise donc l'apparition de l'étiquette cortex plus on s'éloigne de cette surface (vers les niveaux de gris les plus clairs).



FIG. 6.8 – Planche de l'image de la fonction de potentiel  $\phi_{NCE}$  de localisation spatiale

Cette image est équivalente à celle de la figure 6.7, mais concerne cette fois les noyaux centraux ; plus on se rapproche de la surface du cerveau, plus l'apparition de l'étiquette noyaux est défavorisée.

connaissant l'ordre de grandeur de  $D_{max}$  dans les cerveaux d'adultes (5 à 6 cm), nous avons fixé empiriquement  $\varphi$  à 0,25.

	AIR	LCR	CTX	NCE	SBL
AIR	-1	0	1	2	3
LCR	0	-1	0	0	1
CTX	1	0	-1	1	0
NCE	2	0	1	-1	0
SBL	3	1	0	0	-1

TAB. 6.2 – Matrice de Potts pour la segmentation du cerveau en 5 classes

La coupe axiale de droite de la figure 6.9, ainsi que la planche de coupes axiales de la figure 6.10, illustrent les résultats obtenus. La régularisation est de force similaire à celle de la figure 6.6, qui ne présente pas de fonctions de potentiel de localisation. Ces dernières sont très rarement utilisées en imagerie médicale ; nous n'avons trouvé qu'un unique cas de leur emploi [KARS-90], et il ne se rapporte ni à l'imagerie par résonance magnétique, ni à l'imagerie cérébrale. Pourtant, les fonctions de potentiel de localisation permettent de distinguer facilement le cortex et les noyaux centraux, et les résultats sont probants ; la comparaison avec une classification contextuelle locale (coupe axiale de gauche de la figure 6.9) met en évidence la qualité de la segmentation obtenue pour les ventricules, les noyaux, et l'interface { substance blanche/substance grise }. Cependant, la segmentation n'est pas parfaite. Une partie de la tête des noyaux caudés, par exemple, est classifiée cortex ; cette erreur est due à la définition approximative des fonctions de potentiel, liée à la morphologie de l'encéphale. En effet, jusqu'à la première coupe du troisième rang de la figure 6.8, nous pouvons observer l'influence de la forme en « U » de la partie inférieure de l'encéphale dans le plan axial ; cette influence, malgré la fermeture morphologique, se traduit par un potentiel  $\phi_{NCE}$  encore fort dans la région de la tête des noyaux caudés.

Pour que l'introduction de fonctions de potentiel de localisation permette d'obtenir de très bons résultats, il faudrait que la forme de ces fonctions soit assez proche de celle des structures dans l'image. Nous avons volontairement utilisé une information grossière pour construire ces fonctions : la distance à la surface du cerveau ; une telle information, bien qu'elle soit adaptée à nos données grâce à la segmentation du cerveau, n'est pas suffisament précise, et des défauts apparaissent. Une solution qui nous semble particulièrement prometteuse pour l'obtention de fonctions de potentiel de localisation pertinentes est l'utilisation d'un atlas probabiliste, après qu'il est mis en correspondance avec l'image à traiter.

# 6.4 Généralisation à des sites et des topologies quelconques

Dans cette section, nous abandonnons les sites voxéliques pour des approches récentes qui suivent encore une démarche markovienne, mais sur des graphes de topologie quelconque.

#### 6.4.1 Problématique

L'algorithme des modes conditionnels itérés est employé majoritairement pour réaliser des classifications markoviennes sur l'ensemble des voxels des images IRM 3D; cela est dû au fait que sur de telles données exhaustives, l'exécution d'un algorithme stochastique s'avère être une tâche bien trop longue. Pourtant, le risque majeur de l'emploi d'un algorithme déterministe est d'aboutir à une





L'image de gauche, coupe axiale de  $xavT_1$ , est obtenue par une classification contextuelle locale avec filtrage par la moyenne (de façon similaire à la planche 6.3); les cinq classes présentées sont : le fond (blanc), le liquide céphalo-rachidien (noir), le cortex (gris foncé), les noyaux centraux (gris moyen), et la substance blanche (gris clair). Avec les mêmes centres de classes, la classification markovienne par l'algorithme des modes conditionnels itérés donne, grâce aux fonctions de localisation, l'image de droite.

segmentation très sous-optimale, ce risque étant d'autant plus grand que les fonctions potentielles sont fixées empiriquement et qu'alors, le paysage énergétique des réalisations peut avoir un relief inattendu.

Les relaxations markoviennes stochastiques qui considèrent que chaque voxel est un site à part entière présentent deux inconvénients majeurs :

- l'obtention d'un résultat presque optimal nécessite que la convergence soit lente ; celle-ci doit être d'autant plus lente que l'on fait intervenir plus de termes de potentiels, car alors le risque de créer un paysage énergétique accidenté est plus important,
- la prise en compte de cliques d'ordre élevé afin de caractériser l'aspect macroscopique des textures (et non plus microscopique) est délicate à mettre en œuvre; en effet, fixer de manière empirique ces paramètres devient alors très peu intuitif, et leur estimation beaucoup plus difficile.

Si nous souhaitions affiner notre modèle énergétique en lui ajoutant des termes supplémentaires, nous ne pouvons pas nous affranchir de l'utilisation d'un algorithme stochastique et, dans l'état actuel de nos connaissances, il nous serait impossible d'obtenir rapidement des résultats.

À nombre de classes, expressions énergétiques et décroissance de la température identiques, de nouvelles approches proposent de réduire le coût calculatoire d'une relaxation stochastique grâce à une hiérarchisation de l'information, une telle démarche permettant également des traitements plus pertinents.



FIG. 6.10 – Segmentation de  $xavT_1$  par classification markovienne par ICM, avec des potentiels de localisation

Cette planche, constituée des mêmes coupes axiales que les figures de cette section 6.3.2, peut être comparée à la figure 6.6; elle est issue d'une relaxation markovienne similaire, à laquelle un terme d'énergie de localisation a été rajouté afin de distinguer les classes cortex et noyaux centraux.

# 6.4.2 État de l'art

La plupart des approches sont fondées sur une appréhension différente de l'ensemble des sites voxéliques à classifier ; elle se traduit par l'élaboration d'une hiérarchie de sites comportant différents niveaux. Les niveaux élevés de la hiérarchie correspondent à une vision plus globale de l'image, et les niveaux bas, à une vision plus locale.

Les approches peuvent être regroupées en catégories :

- Dans une approche multi-résolutions pyramidale [GIDA-89] [LAKS-93] [PERE-93], le niveau le plus bas est l'ensemble des sites de l'image. La hiérarchie est construite progressivement en restreignant l'ensemble des sites d'un niveau à un sous-ensemble des sites du niveau immédiatement inférieur; citons par exemple, une décimation discrète ou par blocs. L'algorithme d'optimisation est multi-grilles et souvent descendant: le résultat de l'optimisation à un niveau sert d'initialisation à l'optimisation au niveau inférieur. L'inconvénient de cette approche est que son caractère markovien n'est pas toujours vérifié.
- Une autre approche multi-résolutions, qui connaît un franc succès à l'heure actuelle, est une technique multi-échelles [BOUM-91] [KATO-93] [HEIT-94]. Cette fois-ci, l'image entière (et non plus seulement une restriction de l'image) sert d'observation à tous les niveaux de la hiérarchie ; la forme des fonctions potentielles suit un modèle rigoureusement markovien mais de plus en plus grossier lorsque le niveau augmente. L'optimisation est alors contrainte par les réalisations déjà visitées et se résume à l'exploration d'espaces de configurations emboîtés.
- Un champ de Markov peut aussi être défini sur un graphe unique décrivant l'ensemble des sites de la hiérarchie [ZERU-94]. Chaque niveau décrit une décomposition de l'image en régions disjointes, la décomposition étant moins forte lorsque le niveau augmente. Chaque région est symbolisée par un nœud du graphe. L'adjacence spatiale de deux régions d'un même niveau se matérialise par un arc du graphe tiré entre les deux nœuds correspondants; il en est de même pour l'intersection de deux régions appartenant à deux niveaux successifs. L'optimisation est alors obligatoirement itérative.
- Un cas particulier survient si les régions d'un niveau donné sont un regroupement des régions du niveau immédiatement inférieur; le graphe se réduit alors à un arbre (il y a surjection des nœuds du sous-graphe défini à un niveau vers ceux du niveau supérieur) [BOUM-92] [LUET-93]. La causalité de ce modèle permet une résolution non-itérative beaucoup plus rapide que dans le cas général.
- Enfin, certains modèles, hybrides, mélangent ces différentes approches [AZEN-92] [REGA-93].

Grâce à de telles approches, une convergence déterministe fournit des résultats approchant ceux d'un algorithme markovien stochastique mené sur l'ensemble des sites voxéliques, et avec un coût de calcul comparable à celui d'un algorithme déterministe appliqué à ce même ensemble.

Enfin, remarquons que l'approche hiérarchique par arbre présente une bonne adéquation entre la description hiérarchique emboîtée des régions de cette approche et la réalité de l'anatomie des structures cérébrales. On préférera aux hiérarchies rigides, qui fixent la morphologie des régions, les hiérarchies adaptatives qui partitionnent l'image en régions adaptées aux données qu'elle contient.

Pour former ces hiérarchies, plusieurs méthodes sont envisageables dont les plus classiques procèdent en deux étapes : la première divise l'image en régions puis la seconde fusionne progressivement les régions [PAVL-77], les techniques et les règles mises en œuvre lors de ces étapes étant très variées (croissance de région, diagramme de Voronoï, etc). Plus récemment, des méthodes garantissant un certain nombre de propriétés du graphe d'adjacence et des données sous-jacentes ont été développées [MEER-89] [MONT-91] [JOLI-92] [MATH-93].

#### 6.4.3 Classification de bassins versants

Nous avons développé une classification markovienne non hiérarchique où un site correspond à une région de l'image; la décomposition de l'image en régions provient d'une extension à la 3D de l'algorithme morphologique de la ligne de partage des eaux [VINC-91], qui devient surface de partage des eaux.

La surface de partage des eaux, 18-connexe, produit une décomposition d'une image en un ensemble de régions appelées bassins versants, non-connexes au sens de la 6-connexité et sans cavité ni tunnel (pour toute notion de topologie discrète en 3D, on peut se reporter à [KONG-89] [SAHA-94a] et [BERT-94b]). De par sa construction, cette surface se positionne sur les crêtes des valeurs d'une image et chaque bassin qu'elle forme entoure un minimum local de ces valeurs.

Afin que la surface de partage des eaux corresponde à une sursegmentation, il suffit de la calculer sur le gradient de l'image à segmenter. Une région homogène dans une image IRM 3D se caractérise par un amas spatial de voxels de niveau radiométrique à peu près constant; aussi, le gradient est faible au sein de l'amas et fort sur sa surface. Cet amas forme donc un bassin versant.

Le nombre des bassins versants produits par l'algorithme de la surface de partage des eaux est fonction du nombre de minima locaux du gradient de l'image à segmenter. L'emploi d'une fermeture morphologique après le calcul du gradient permet de réduire ce nombre de minima; la figure 6.11 montre une coupe des surfaces résultantes, respectivement lorsque le gradient n'est pas fermé, est fermé sur un 6-voisinage et sur un 18-voisinage. Bien entendu, plus la fermeture est forte, plus le nombre de bassins versants produits diminue.

De la décomposition de l'image en bassins nous déduisons le graphe d'adjacence. Un nœud représente un bassin dont les seules caractéristiques sont la liste des voxels qui le constituent. Avant d'effectuer la classification, nous avons choisi de réduire l'espace des caractéristiques en considérant qu'un noeud n'a pour informations significatives que :

- le nombre de voxels constituant le bassin,
- les coordonnées 3D du centre de masse du bassin,
- la radiométrie moyenne du bassin.

Bien entendu, un nœud connaît aussi son état, succeptible de changer au cours de la classification, ainsi que la liste des arcs qui le relient à d'autres nœuds.

Classifier revient à attribuer une classe à un bassin versant ; les sites de notre optimisation markovienne sont donc les nœuds du graphe. Nous aurions pu opter pour un ensemble de caractéristiques différent mais celui-là nous a paru pertinent parce que très proche de celui d'un site voxélique.

Dans le graphe, un arc entre deux nœuds s et s' matérialise l'adjacence de deux bassins versants ; ce graphe est bien un graphe d'adjacence de régions de l'image. Tout arc correspond à un ensemble de voxels de la surface de partage des eaux, ensemble que nous appellerons par la suite un élément de surface. Les voxels qui forment un élément de surface entre deux bassins sont tels que ces deux bassins soient représentés dans leurs 6-voisinages (cette définition tient compte du fait qu'un voxel de la surface de partage des eaux peut avoir jusqu'à six bassins versants dans son 6-voisinage).





FIG. 6.11 – Surfaces de partage des eaux

Les images (b), (c) et (d) représentent la coupe n°60 des surfaces de partage des eaux calculées respectivement sur le gradient de  $x a v T_1$  et sur ce même gradient fermé sur un 6-voisinage et sur un 18-voisinage; ces surfaces délimitent respectivement 390 302, 20 397 et 7 542 bassins versants et la forme de ces derniers peut être comparée à celle des structures cérébrales de l'image IRM 3D originale dont la coupe correspondante est portée en (a).

Notons a(s, s') le nombre de voxels appartenant à un élément de surface qui sépare les deux bassins de sites s et s'. Les éléments de surfaces qui correspondent à un arc ne sont pas classifiés car ce ne sont pas des sites du graphe ; néanmoins, nous aurions pu faire intervenir dans la classification, par les termes d'énergie contextuelle par exemple, d'autres informations que ce nombre de voxels. Nous ne l'avons pas fait afin que la classification markovienne sur graphe d'adjacence soit similaire à celle qui s'appuie sur des sites voxéliques (section 6.3); en effet, pour ce dernier, l'adjacence de deux voxels n'est porteuse d'aucune information intrinsèque.

Nous avons utilisé la même matrice de Potts (définie dans le tableau 6.1) que pour la classification voxélique. Comme le terme d'énergie contextuelle qui s'en déduit s'applique maintenant aux sites d'un graphe et non plus aux voxels, une adaptation a été nécessaire.

Pour l'observation radiométrique  $x_s^{\text{gra}(I)}$  en un site *s* du graphe gra(I) défini sur l'image *I*, nous avons pris la moyenne radiométrique des voxels du bassin correspondant à *s*; cela a un sens car la radiométrie d'un voxel provient de l'intégration d'une mesure physique sur son volume. Le terme d'énergie d'attache aux données reste inchangé.

Avec le modèle voxélique en un site donné, nous avions fait intervenir six contributions au terme d'énergie contextuelle locale; elles étaient dues aux cliques d'ordre deux instanciées sur le 6-voisinage de ce site. Avec un modèle régional en revanche, le nombre d'arcs qui partent d'un site, autrement dit le nombre de cliques d'ordre deux, est variable. Pour que l'ensemble de leur contribution reste du même ordre que celui du modèle voxélique, une normalisation s'impose. Aussi, nous avons étendu l'équation (6.14) en :

$$U_s(X^{(t)}) = 3 \frac{\sum_{s' \in V_s} a(s, s') f_{c^2}(y_s^{(t)}, y_{s'}^{(t)})}{\sum_{s' \in V_s} a(s, s')}.$$
(6.15)

Notons que cette expression tient compte de la disproportion entre les différentes adjacences d'une même région ; une frontière plus importante a une plus forte pondération de sa contribution au terme d'énergie contextuelle locale.

L'optimisation est réalisée par l'algorithme de Métropolis avec un recuit simulé. Nous nous sommes efforcés de rendre la classification markovienne sur graphe équivalente à celle qui a été menée sur les voxels ; aussi, le recuit conserve les mêmes paramètres qu'en section 6.3.2.

Les figures 6.12, 6.13 et 6.14 donnent les résultats de la classification markovienne sur les graphes issus des trois surfaces de partage des eaux représentées en figure 6.11; ces trois résultats s'appuient donc sur des régions de plus en plus volumineuses (les moyennes du nombre de voxels des bassins versants sont respectivement de l'ordre de 5, 180 et 480). Pour cette raison, la première figure est celle dont le résultat se rapproche le plus d'une classification markovienne sur sites voxéliques (Cf. figure 6.5).

Le premier résultat de la relaxation sur graphe (sans fermeture de l'image du gradient) comporte quelques défauts :

- les structures les plus fines disparaissent (c'est le cas des capsules blanches et d'une bonne partie des sillons),
- la forme des circonvolutions corticales est dégradée (en particulier, celles qui sont presque touchantes dans l'image originale sont maintenant adjacentes),
- certaines petites régions n'ont pas été régularisées (cela est dû au fait qu'elles sont constituées de voxels bruités, ce qui leur donne des attaches aux données incorrectes, et que leur adjacence avec leurs régions voisines est trop faible, ce qui rend trop faible l'influence de leurs contextes).

Le deuxième résultat (avec une 6-fermeture de l'image du gradient) présente avec une certaine amplification ces deux premiers défauts. En revanche, le défaut de trop faible régularisation n'apparaît plus. En effet, la régularisation imposée par l'étape morphologique précédant la constitution de la sursegmentation fournit des bassins de volumes plus importants, et le moyennage radiométrique de



FIG. 6.12 – Segmentation de  $xavT_1$  par classification markovienne sur graphe d'adjacence de régions

A partir de la décomposition de l'image  $xavT_1$  en 390 302 bassins versants (figure 6.11, illustration (b)), un graphe d'adjacence est construit et une relaxation markovienne avec recuit classifie les bassins; les voxels de la surface de partage des eaux sont affectés à la classe majoritaire dans leur voisinage. chaque bassin permet de s'affranchir du bruit des voxels de l'image. La régularisation markovienne donne au final des régions de surfaces bien lisses. En particulier, la forme des noyaux centraux est très correcte ; le seul problème rémanent est que ces noyaux sont connectés au cortex.



FIG. 6.13 – Segmentation de  $xavT_1$  par classification markovienne sur graphe d'adjacence de régions (6-fermeture)

Cette segmentation est menée de façon similaire à celle de la figure 6.12 mis à part que le graphe comporte moins de bassins (20 397); cela est dû à l'introduction d'une 6-fermeture, appliquée à l'image de gradient de l'acquisition originale avant le calcul de la surface de partage des eaux (figure 6.11, illustration (c)).

Le troisième résultat (avec une 18-fermeture de l'image du gradient) est déplorable, et les régions sont trop grossières.

#### 6.4.4 Classification complète

La classification markovienne porte uniquement sur les bassins versants ce qui exclut les voxels de la surface de partage des eaux. Pour présenter les résultats des figures 6.12, 6.13 et 6.14, nous



FIG. 6.14 – Segmentation de  $xavT_1$  par classification markovienne sur graphe d'adjacence de régions (18-fermeture)

Cette segmentation est menée de façon similaire à celle de la figure 6.13 mais avec une 18-fermeture au lieu de la 6-fermeture ; le graphe sur lequel est réalisée la relaxation markovienne possède encore moins de sites (7 542), régions de l'image à étiqueter (figure 6.11, illustration (d)).

avons affecté chaque voxel de la surface de partage des eaux à l'étiquette majoritaire de ses voxels 18-voisins, en ne considérant que ceux qui appartiennent aux bassins. Le problème de la classification de ces voxels reste entier.

La surface de partage des eaux représente dans l'image une proportion importante de ses voxels ; dans les trois cas que nous avons traités, il s'agit respectivement de 54 %, de 30 %, et de 24 % de la totalité des voxels de l'image. Laisser de côté de telles quantités d'informations n'est pas raisonnable. Bien que nous n'ayons pas abordé ce problème dans nos mises en œuvre, donnons une piste pour prendre en considération dans la classification les informations contenues dans la surface de partage des eaux.

Les éléments de surface qui séparent deux bassins adjacents sont généralement de trois types différents (Cf. figure 6.15):

- A certains font partie intégrante de la structure qui comprend les deux bassins adjacents,
- B certains sont des limites entre deux structures distinctes auxquelles les deux bassins appartiennent,
- C certains sont d'une structure séparatrice différente de la structure à laquelle (ou des deux structures auxquelles) les deux bassins appartiennent.



FIG. 6.15 – Différents types d'éléments de surface de partage des eaux

Ces trois exemples illustrent les différents types d'éléments de ligne (analogie 2D des éléments de surface) de partage des eaux. La ligne d'épaisseur 1 voxel est représentée par son coutour (en noir); les différents gris du fond des schémas symbolisent la radiométrie moyenne de chaque bassin et de chaque élément de ligne; l'élément de ligne auquel nous nous intéressons est hachuré. Ce dernier fait partie intégrante de la structure qui comprend ses deux bassins versants adjacents (**A**), est une limite entre deux structures distinctes auxquelles les deux bassins appartiennent (**B**), ou fait partie d'une structure séparatrice différente des structures auxquelles les deux bassins appartiennent (**C**).

Les éléments de type **A** apparaissent parce que la surface de partage des eaux nous fournit une sursegmentation, une même structure cohérente pouvant présenter plusieurs minima locaux de radiométrie. La radiométrie moyenne de ces éléments de surface n'est donc pas très différente de celles des deux bassins adjacents correspondants.

Les éléments de type **B** ne correspondent pas à une structure particulière; ils sont constitués presque exclusivement de voxels de mélange des deux structures qui se trouvent de part et d'autre. La radiométrie moyenne de ces éléments de surface est donc intermédiaire de celles des deux bassins adjacents correspondants.

Les éléments de type **C** représentent des structures surfaciques de l'image. En imagerie par résonance magnétique du cerveau, ce sont par exemple les sillons et une partie du troisième ventricule (de classe liquide céphalo-rachidien), les capsules et les régions blanches séparant les circonvolutions corticales (de classe substance blanche), le noyau du fornix entre la tête et le corps des deux ventricules latéraux (de classe substance grise), etc. La radiométrie moyenne de ces éléments de surface est donc différente de celles des deux bassins adjacents correspondants.

Jusqu'à présent, nous formions un graphe de deux façons pour effectuer une relaxation markovienne : l'ensemble de sites était, soit l'ensemble des voxels de l'image (section 6.3), soit l'ensemble des bassins versants (section 6.4.3). Nous suggérons ici une idée de modification de cette dernière structure de graphe.

Les éléments de surface, tels que nous les avons définis en section 6.4.3 pour former les arcs de notre graphe, ne vont plus convenir. La raison en est que les voxels de la surface de partage des eaux peuvent être pris en compte dans plusieurs éléments de surface (Cf. figure 6.16); ce n'est pas gênant car l'énergie locale d'expression 6.15 normalise le nombre de voxels des éléments de surface correspondant à tout bassin. Au contraire, cela permet à de très petites éléments de surface d'avoir une contribution à cette énergie ; dans le cas du graphe montré en image (d) de la figure 6.11, si nous avions écarté de tels voxels, de nombreux éléments de surface n'auraient contenu aucun voxel.



FIG. 6.16 – Cas d'un point surfacique connexe à plus de 2 bassins

Sur cette illustration, la ligne (analogie 2D de la surface) de partage des eaux apparaît en blanc, l'intérieur de trois bassins différents en gris, et le point qui nous intéresse en contour noir épais. Avec la définition d'un élément de surface donnée en section 6.4.3, ce point participe aux trois éléments de ligne; en effet, son 4-voisinage (analogie 2D du 6-voisinage) contient un point de chaque bassin. Avec la nouvelle définition, il n'appartient plus qu'à l'élément de ligne du haut, puisque son 8-voisinage (analogie 2D du 18-voisinage), ici en pointillé, contient majoritairement des points du bassin gauche et du bassin supérieur droit.

Maintenant, le cas de ces voxels pose problème car nous ne souhaitons plus qu'un voxel de surface puisse contribuer à deux éléments de surface distincts. Nous proposons de modifier la définition d'un élément de surface : les voxels qui forment un élément de surface entre deux bassins sont tels que ces deux bassins sont représentés dans leurs 6-voisinages, tels que ces deux bassins sont les plus représentés dans leurs 18-voisinages, et tels qu'ils n'ont pas déjà été sélectionnés pour un autre élément de surface (Cf. figure 6.16). Au final, l'ensemble des voxels des éléments de surface est le même qu'en section 6.4.3 mais un voxel d'un élément de surface ne peut plus appartenir à un autre élément.

Avec cette nouvelle définition comme avec l'ancienne, certains voxels de la surface de partage des eaux ne sont pas affectés à un élément de surface car ils n'ont dans leurs 6-voisinages que des voxels de la surface [VINC-91]. Un tel voxel, que nous appelons « drapeau », peut apparaître au confluent de plusieurs eaux ; il est donc connexe à plusieurs éléments de surface. Un exemple de ce

type de voxel est montré en 2D dans la figure 6.17.

A partir d'une sursegmentation obtenue par l'algorithme de la surface de partage des eaux, trois sortes de voxels peuvent être distinguées :

- 1. les voxels des bassins (régions 6-connexes),
- 2. les voxels des éléments de surface (18-connexes) séparatrices entre deux bassins,
- 3. les voxels « drapeau » de la surface de partage des eaux.

Nous proposons donc de définir un graphe constitué de trois sortes de sites (Cf. figure 6.17):

- 1. un site pour chaque bassin versant,
- 2. un site pour chaque élément de surface,
- 3. un site pour chaque voxel drapeau.

Ainsi, un voxel de l'image appartient à un et un seul site; les sites peuvent être considérés comme indépendants statistiquement. En particulier, une caractéristique de tout site sera sa moyenne radio-métrique qui sert au terme d'attache aux données.

En conséquence, trois sortes d'arcs sont définies (Cf. figure 6.17):

- un arc qui relie un bassin à un de ses éléments de surface,
- un arc qui relie un élément de surface à un autre élément de surface qui lui est 18-connexe,
- un arc qui relie un voxel drapeau à un des éléments de surface qui lui sont 6-connexes.



FIG. 6.17 – Nouvelle définition d'un graphe à partir de la surface de partage des eaux

Le schéma de gauche montre une ligne (analogie 2D d'une surface) de partage des eaux en blanc, ainsi que quatre bassins versants en gris ; les sites du sous-graphe correspondant à ce schéma sont de trois types : les sites associés à un bassin (type 1), ceux associés à un élément de ligne (type 2), et le point drapeau (type 3). Ce point, bien que la ligne de partage des eaux soit d'épaisseur 1 point, n'a pas de 4-voisin (analogie 2D du 6-voisin) dans un bassin ; c'est bien un point drapeau. Le schéma de droite présente le sous-graphe : le site d'un bassin est représenté par un disque, celui d'un élément de surface par un carré blanc, et celui du point drapeau par un losange. Les arcs de ce sous-graphe sont symbolisés par les lignes noires.

La classification des éléments de surface, qui est l'apport original de cette réflexion, peut maintenant tenir compte des trois types d'éléments de surface que nous avons distingués au début de cette section. Si un élément de surface est lié à deux bassins de même état, il est vraisemblablement du type A (à l'intérieur d'une structure) ou C (structure séparatrice); s'il est lié à deux bassins d'états différents, il est vraisemblablement du type B (surface de mélange entre les deux structures voisines) ou C (structure séparatrice).

Son étiquetage dépend de son attache aux données, de la compatibilité de son étiquette avec celles de ses deux bassins voisins et de ses éléments de surface voisins, de sa cardinalité en nombre de voxels et de celles de ses voisins. Ces compatibilités peuvent s'exprimer avec des fonctions de potentiel.

Enfin, la classification des bassins et des voxels drapeaux se traduit aussi en énergie contextuelle, de façon semblable que dans l'expression (6.15), à l'exception près que les sites s' sont des éléments de surfaces et non plus des bassins.

Nous n'avons pas expérimenté cette idée originale ; nous la présentons donc à titre de perspective. Son intérêt principal est de distinguer les objets de forme volumique et les objets de forme surfacique. Cette distinction, qui correspond à une réalité de l'anatomie cérébrale, permet d'éviter la disparition des structures surfaciques dans l'image, disparition due à leur morphologie et à la régularisation.

# 6.5 Conclusion

Dans ce chapitre, nous avons évalué différentes méthodes qui assurent une bonne cohérence des structures :

- 1. régularisation de classifications non-contextuelles (figure 6.2),
- 2. classifications contextuelles locales (figures 6.3 et 6.4),
- 3. classifications markoviennes sur les voxels (figures 6.5, 6.6, et 6.10),
- 4. classifications markoviennes sur un graphe d'adjacence de régions (figure 6.13 par exemple).

Toutes ces méthodes s'appuient sur la notion de contexte.

Pour les trois premières méthodes, le sujet de la classification est le voxel, et le contexte du voxel est son voisinage. La dernière méthode est une extension de la relaxation markovienne sur les voxels ; le sujet de la classification est alors la région, et son contexte, les régions adjacentes.

De plus, les deux dernières méthodes, markoviennes, permettent aisément la prise en compte d'un contexte spatial relatif; en section 6.3.2 page 130, un voxel est caractérisé par sa distance à la périphérie du cerveau, grâce à l'introduction de termes d'énergie de localisation.

Pour les régularisations de classifications non-contextuelles, l'affectation d'un voxel à une classe est effectuée en deux temps : une classe temporaire est attribuée à chaque voxel par une classification non-contextuelle, puis la classe finale d'un voxel est déterminée par une régularisation des classes sur le voisinage de ce voxel. En revanche, pour les classifications contextuelles locales, la décision d'affectation d'une classe à un voxel est repoussée à la seconde étape, la première étape consistant à régulariser les données. Ce dernier type de méthodes donne naturellement de bien meilleurs résultats.

La classification ne devient globale qu'avec les méthodes markoviennes : la décision d'une classe en un voxel dépend des données en ce voxel et des classes de son voisinage. Nous avons mis en œuvre des algorithmes d'optimisation par relaxations stochastique et déterministe (section B.2). Les résultats de l'algorithme déterministe des modes conditionnels itérés sont aussi bons que ceux de l'algorithme stochastique de Métropolis; notre préférence se porte sur le premier, beaucoup plus rapide que le second. La sensibilité des résultats des classifications markoviennes aux coefficients de la matrice de Potts s'avère plutôt faible; le seul réglage délicat reste la pondération entre le terme d'attaches aux données et le terme contextuel (formule 6.10). L'estimation de ces hyperparamètres reste une piste de recherche, qui pourrait s'inspirer par exemple de [SIGE-97].

Pour une segmentation en quatre classes (fond, liquide céphalo-rachidien, substance grise, et substance blanche), la classification contextuelle locale (figure 6.3) et la classification markovienne (figure 6.6) donnent des résultats comparables. Cette constatation mérite d'être discutée. Dans ces deux exemples, seul le mode de régularisation est différent. Imposer de fortes contraintes de régularisation n'est pas envisageable car cela détruirait les structures anatomiques cérébrales, généralement peu épaisses; nous sommes obligés de nous limiter à une régularisation légère, et finalement, les résultats des approches locales et globales sont comparables.

En revanche, l'introduction d'informations *a priori* supplémentaires est facilitée par le cadre markovien; elles s'expriment de façon très intuitive. La localisation spatiale, par exemple, nous a permis d'obtenir des résultats remarquables de classification (figure 6.10), dans lesquels le cortex et les noyaux centraux forment deux classes distinctes, et non plus la classe unique de substance grise.

Nous avons aussi développé une méthode de relaxation markovienne sur un graphe d'adjacence des régions de l'image (en section 6.4.3), où ce graphe est construit à partir de la surface de partage des eaux. L'utilisation d'une sur-segmentation permet une réduction importante de la complexité de la relaxation, et donc du temps de calcul ; mais en contrepartie, la sur-segmentation ne préserve pas la finesse des données voxéliques, et la classification finale est bien moins bonne qu'une classification markovienne équivalente menée sur les voxels.

Ce problème est lié au fait que seuls les bassins versants, délimités par la surface de partage des eaux, sont classifiés ; la surface est donc laissée pour compte, ainsi que la masse d'informations radiométriques et contextuelles que ses voxels contiennent. Nous avons suggéré, comme perspective de ce travail, une méthode originale d'élaboration d'un graphe à partir de la surface de partage des eaux (en section 6.4.4). L'ensemble des sites correspond alors à la totalité des voxels de l'image, et les éléments de la surface ne sont pas traités de la même façon que les bassins versants.

# **Chapitre 7**

# Approche contextuelle par morphologie mathématique

A l'instar du chapitre précédent, nous utilisons dans ce nouveau chapitre des informations contextuelles pour segmenter des structures internes du cerveau, informations du même type que celles utilisées dans le chapitre 6 (voisinage et localisation spatiale). En revanche, il ne s'agit plus de méthodes statistiques de classification, et le formalisme qui permet d'introduire ces informations est différent.

Nous employons maintenant des méthodes de morphologie mathématique. Ce domaine du traitement d'images, qui a vu le jour à l'École des Mines de Paris sous l'impulsion de G. Matheron puis de J. Serra [HAAS-67], a donné lieu depuis à de nombreux développements [VINC-92][BLOC-93], et à la parution d'ouvrages de référence [SERR-82][SERR-88][SCHM-94].

Le point de départ des chaînes de traitements que nous allons présenter est le plus souvent une étape de seuillage binaire : l'application d'une fonction discriminante dans l'espace des radiométries tire parti des caractéristiques des matières présentes dans les images IRM pour sélectionner un objet, ou plus souvent un ensemble d'objets.

Nous présentons des méthodes, souvent originales, pour segmenter successivement le cerveau (section 7.2), le liquide céphalo-rachidien (section 7.3), en distinguant ventricules et LCR des sillons, et la matière grise (section 7.4), en distinguant cortex et noyaux gris centraux. La cohérence globale de ces segmentations, menées en partie indépendamment les unes des autres, est assurée par un post-traitement imposant des priorités entre les différentes détections (section 7.5). La matière blanche est obtenue par simple différence entre le cerveau et toutes les structures détectées.

Une seule acquisition est utilisée (contrairement à certaines classifications effectuées dans la partie II), correspondant à une acquisition clinique standard en  $T_1$ . Tous les traitements sont tridimensionnels et prennent en compte l'anisotropie des voxels. Le but de ce chapitre est de montrer que l'on peut aller assez loin dans la segmentation à l'aide d'outils morphologiques. Les résultats obtenus peuvent servir de base à des traitements associant la morphologie mathématique à d'autres techniques, et à la reconnaissance des formes.

Au cours du chapitre, nous illustrons les différentes étapes des méthodes développées sur une image typique,  $xavT_1$ . Dans l'annexe C, nous présentons des résultats sur des images variées et acquises selon différents modes, faisant partie de la base de données constituée dans le cadre d'un

projet financé par le GIS Sciences de la Cognition.

#### 7.1 Paramètres

Avant de décrire les différentes méthodes de segentation, nous précisons dans cette section le type de paramètres que nous allons utiliser tout au long de ce chapitre. Ces paramètres sont de deux types : les niveaux de gris caractéristiques des différentes structures, et les éléments structurants utilisés dans les opérations morphologiques.

Les premiers sont utilisés essentiellement pour des seuillages préliminaires. La moyenne et l'écart-type de chaque structure d'intérêt peuvent être obtenus par apprentissage, soit supervisé comme dans la partie II, soit de manière automatique. Les résultats présentés dans ce chapitre et dans l'annexe C sont tous obtenus avec un apprentissage automatique des fonctions d'appartenance floues (voir chapitre 5 et [BLOC-97a]). Cette méthode permet de déduire la moyenne et l'écart-type de chaque structure en pondérant chaque voxel par son degré d'appartenance à cette structure. Les estimations tiennent ainsi compte du volume partiel, et peuvent être directement utilisées pour seuiller les images. Notons qu'il ne s'agit pas ici des caractéristiques des structures pures, mais des caractéristiques telles qu'elles apparaissent dans l'image (typiquement, la moyenne du liquide céphalo-rachidien des sillons dans les images est plus élevée que celle du liquide céphalo-rachidien pur, à cause de l'important effet de volume partiel dans ces très fines structures).

Les paramètres du deuxième type sont les tailles des éléments structurants choisis. Afin que les méthodes soient indépendantes de la taille des voxels, nous fixons toutes les tailles en millimètres, et nous les estimons d'après la taille des structures (par exemple, le cortex est un ruban d'environ 3 mm d'épaisseur). L'anisotropie des voxels est également prise en compte, comme décrit dans l'annexe A.

#### 7.2 Segmentation du cerveau

Avant de mener à bien la segmentation des structures internes du cerveau, une première étape incontournable est d'isoler la région d'intérêt dans l'acquisition IRM 3D correspondant au cerveau. Nous proposons pour cela une méthode similaire à celles proposées dans [MANG-95][VERA-95], mais comportant un peu plus d'opérations, qui garantissent une meilleure robustesse aux variations anatomiques et des acquisitions.

#### 7.2.1 Description de la méthode

Cette méthode se compose d'un enchaînement de différents traitements partant d'une acquisition unique ; les résultats intermédiaires sont illustrés par la série d'images de la figure 7.1.

1. Seuillage pour faire apparaître un objet cerveau.

La valeur basse est estimée à partir de la moyenne et l'écart-type des ventricules ( $\mu_{ven}$  et  $\sigma_{ven}$ ), et la valeur haute à partir des caractéristiques de la substance blanche ( $\mu_{blanc}$  et  $\sigma_{blanc}$ ):

$$s_1 = \mu_{ven} - \sigma_{ven},\tag{7.1}$$

$$s_2 = \mu_{blanc} + 2\sigma_{blanc}. \tag{7.2}$$

Après seuillage, l'air et l'os (de radiométrie faible), les yeux, le sang et la graisse (de radiométrie forte), se retrouvent dans le fond de l'image binaire. L'objet quant à lui est constitué de la peau et du cerveau ; ce dernier comprenant des vaisseaux sanguins (radiométrie très forte), on note que l'objet obtenu comporte des trous.

2. Érosion pour garantir la séparation cerveau/peau.

Dans certaines images, le crâne, trop fin par endroits, induit la connexion du cerveau avec la peau. Pour prévenir l'impossiblité d'une séparation ultérieure de ces deux objets, une érosion légère par un élément structurant sphérique de rayon 1,7 mm<sup>1</sup> permet de les écarter.

Bien entendu, les trous apparus lors de l'étape précédente s'en trouvent par conséquent légèrement dilatés.

3. Bouchage de trous pour que l'objet cerveau soit cohérent.

Boucher les trous d'une image binaire consiste à étiqueter les composantes connexes du fond de l'image et à ne garder que celles qui touchent les bords ; les autres composantes, qui sont les trous de l'objet cerveau, sont réaffectées à l'objet.

Nous sommes généralement en présence d'une unique composante du fond très volumineuse, qui couvre entre autres l'air et l'os, et d'une myriade de petites composantes qui doivent effectivement être supprimées. Dans le cas très improbable où l'air et l'os ne seraient pas connectés, une heuristique simple calcule la cardinalité des composantes les plus importantes, et décide le seuil de taille en deçà duquel une composante doit être considérée comme un trou indésirable; si l'os n'est pas connecté à l'air, sa composante est quand même conservée.

A l'issue de ce traitement, l'objet réunit la peau et le cerveau ; ce dernier, nettoyé, forme maintenant un volume non lacunaire.

4. Déconnexion du cerveau et de la peau par érosion.

Pour isoler le cerveau, il faut le séparer de la peau. Dans la majorité des cas, ces deux structures se touchent après le seuillage de l'étape 1 ; cette connexion s'opère au niveau des yeux, des oreilles et du tronc cérébral. On observe même parfois des connexions cerveau/peau au niveau du crâne si ce dernier est trop fin par rapport à la résolution de l'acquisition ou si le contraste entre le crâne et l'ensemble cerveau/peau est insuffisant.

La séparation est réalisée par une érosion morphologique ayant pour élément structurant une sphère de rayon 5,3 mm. A l'issue de l'érosion, la peau forme une fine calotte qui entoure (de loin maintenant) le cerveau dont la surface vient d'être rognée.

5. Marquage du cerveau par étiquetage.

Le cerveau représente la plus volumineuse composante connexe de l'objet de l'image binaire résultant de l'étape précédente. Un étiquetage permet alors de marquer cette composante comme représentant une partie intérieure importante du volume cérébral dans l'image.

6. Reconstruction du volume cérébral par dilatation conditionnelle.

Afin de compenser la perte de la périphérie du volume cérébral due aux érosions successives (étapes 2 et 4), une dilation s'impose. Elle est mise en œuvre conditionnellement à l'objet résultant de l'étape 1 ; son élément structurant est une sphère de rayon 7,1 mm.

<sup>1.</sup> La discrétisation restreinte d'une telle sphère correspond le plus souvent à l'élément structurant de la 6-connexité puisque les dimensions d'un voxel sont typiquement de  $1 \times 1 \times 1, 3$  mm; si l'anisotropie de l'image avait été plus importante, nous aurions, avec cette même justification, utilisé l'élément structurant de la 4-connexité. Notons que l'emploi d'une description métrique des dimensions des éléments structurants, par opposition à une description exprimée en nombre de voxels, permet de s'affranchir des spécificités du système d'acquisition, et de tenir compte de l'anisotropie des voxels, pour mettre en œuvre des traitements isotropes à une approximation près (voir Annexe A).

#### 158 Chapitre 7. Approche contextuelle par morphologie mathématique

Le choix d'un rayon légèrement supérieur à la somme des deux rayons érodants garantit de récupérer dans sa grande majorité le volume cérébral tel qu'il avait été mis en évidence par le seuillage initial.

La forme assez régulière du cerveau explique sa bonne reconstruction après ces étapes dont l'enchaînement s'apparente à une sorte d'ouverture morphologique.

7. Bouchage de cavités éventuelles créées à l'étape initiale.

Le seuillage bas initial fait parfois apparaître dans le fond de l'image le système ventriculaire. Celui-ci forme alors une véritable cavité dans l'objet cerveau, partant de la partie inférieure de l'image et remontant jusqu'à l'intérieur du cerveau. Malheureusement, la dilatation précédente ne parvient parfois pas à faire disparaître totalement cette cavité.

Afin de remédier à cette éventualité, nous effectuons un bouchage au sein de chaque coupe axiale, bouchage pertinent car la forme du cerveau ne doit présenter aucune cavité perpendiculaire au plan axial.

Contrairement à tous les autres traitements que nous effectuons et qui sont tridimensionnels, ce bouchage est exceptionnellement bidimensionnel; notons qu'il n'est généralement pas nécessaire.

8. Obtention du cerveau segmenté.

Nous ne conservons de l'image originale que les voxels correspondant au masque binaire issu de l'étape précédente afin d'obtenir une image du cerveau segmenté; les autres voxels sont mis à  $0^1$ .

#### 7.2.2 Commentaires sur la méthode et sur les résultats obtenus

Cette méthode a été mise en œuvre avec succès sur une dizaine d'acquisitions de divers types, y compris dans des situations délicates : bruit important, basse résolution, présence d'électrodes (voir les résultats dans l'annexe C).

Si l'acquisition initiale est de bonne qualité (bruit réduit, contraste correct) et si l'os y est suffisamment épais, la séparation intérieur/extérieur du cerveau est relativement facile ce qui entraine des simplifications dans la procédure de segmentation :

- l'étape 2 devient superflue,
- la dilatation de l'étape 6 peut se contenter d'une sphère de rayon 5,4 mm,
- l'étape 7 s'avère inutile.

Bien entendu le résultat final est de meilleure facture.

L'image qui nous a servi d'illustration est constituée d'une unique acquisition en  $T_1$  de bonne qualité. Cette méthode aurait tout aussi bien pu être mise en œuvre avec plusieurs acquisitions, le seuillage initial n'en serait que meilleur.

Remarquons toutefois que la segmentation présente un défaut dans la région postérieure du cerveau : une partie du crâne n'a pas pu être supprimée. L'observation de l'image originale montre qu'effectivement la limite du cerveau n'y est pas nette d'un point de vue radiométrique.

<sup>1.</sup> Un raffinement supplémentaire consiste à passer les voxels du cerveau de radiométrie 0 à la radiométrie 1 ce qui nous donne la possibilité de récupérer ultérieurement la segmentation du cerveau (dans le cas où le masque binaire obtenu n'est pas stocké) en effectuant un seuillage binaire des voxels de radiométrie supérieure ou égale à 1. Ce raffinement modifie donc imperceptiblement deux niveaux radiométriques qui ne seront pas importants pour la suite des opérations.



FIG. 7.1 – Segmentation morphologique du cerveau.

Les images de cette figure illustrent sur la coupe n° 60 de  $xavT_1$  les différentes étapes de la segmentation morphologique du cerveau ; l'image numérotée i est le résultat de la  $i^{\text{ème}}$  étape à l'exception de l'image 0, image initiale.

# 7.3 Segmentation du liquide céphalo-rachidien

La segmentation du liquide céphalo-rachidien peut paraître relativement aisée ; un seuillage dans l'image du cerveau résultant de la méthode précédente est presque suffisant (mais la cohérence topologique n'est pas du tout garantie). De plus, la reconnaissance de l'enveloppe cérébrale et des sillons d'une part, et du système ventriculaire d'autre part, peut s'effectuer avec des outils classiques de morphologie mathématique.

Il nous a pourtant paru intéressant de proposer une autre méthode dans les sections 7.3.2 et 7.3.3 que nous justifierons.

#### 7.3.1 Segmentation simple

Une première idée pour parvenir à isoler le liquide du système ventriculaire de celui des sillons s'appuie sur le fait que les ventricules forment des volumes relativement épais tandis que l'enveloppe cérébrale et les sillons forment des surfaces minces.

Voici donc le principe d'une segmentation simple exploitant cette idée :

1. Seuillage du liquide céphalo-rachidien.

Un seuillage entre deux niveaux de radiométrie (pour la valeur basse, la moyenne des caractéristiques de l'air et du liquide, et pour la valeur haute, du liquide et de la susbtance grise) de l'image du cerveau donne le liquide céphalo-rachidien. Ce liquide constitue l'enveloppe cérébrale et remplit les sillons du cortex et le système ventriculaire.

Cette étape peut être précédée d'une fermeture préliminaire du cerveau (de taille 5 mm typiquement), afin de bien fermer les sillons.

2. Érosion morphologique discriminante.

Une érosion en 6-connexité du masque du cerveau élimine une bonne partie de l'enveloppe cérébrale ainsi que des sillons et permet donc de réduire la zone de marquage des ventricules ; une érosion 6-connexe de l'intersection de ce résultat et de l'image seuillée résultant de l'étape 1, suivie d'une fermeture 26-connexe, permet de récupérer le système ventriculaire. Il est érodé mais correspond maintenant aux composantes connexes les plus volumineuses de l'image.

3. Marquage du système ventriculaire.

Un étiquetage des composantes connexes suivi d'un seuillage pour ne conserver que les plus volumineuses d'entre elles fournit donc le système ventriculaire.

4. Reconstruction morphologique.

Une dilatation conditionnelle à l'objet seuillé issu de l'étape 1 permet de retrouver le volume du système ventriculaire érodé à l'étape 2. L'élément structurant est une sphère de rayon 2,6 mm, donc sensiblement plus grande que celle qui a servi à l'érosion ; les parties fines des ventricules peuvent ainsi être récupérées.

5. Soustraction binaire donnant l'ensemble enveloppe/sillons.

Soutraire le système ventriculaire de l'image seuillée de l'étape 1 permet de récupérer uniquement le liquide de l'enveloppe cérébrale et des sillons.

La figure 7.2 présente sur une coupe axiale le résultat de la segmentation des sillons par cette méthode ainsi que, à titre de comparaison, le résultat d'une solution originale que nous présentons par la suite.



FIG. 7.2 – Segmentation morphologique simple des sillons

Cette figure représente la coupe axiale n°60 extraite respectivement des images suivantes : (a) acquisition originale  $xavT_1$ , (b) résultat de la segmentation simple des sillons décrite en section 7.3.1 et (c) résultat de la segmentation améliorée décrite en section 7.3.3.

Nous pouvons constater que cette démarche très simple présente deux inconvénients antagonistes : l'enveloppe cérébrale et les sillons sont victimes de l'effet de volume partiel et peuvent donc lors du seuillage initial disparaître par endroit ; à l'inverse, les sillons obtenus sont souvent trop épais ce qui est contraire à l'anatomie cérébrale. De plus, le nombre de composantes connexes à retenir à l'étape 3 n'est pas toujours facile à déterminer, en particulier si le seuillage conserve des parties importantes du plan inter-hémisphérique. Enfin, cette méthode ne garantit aucune propriété topologique du LCR des sillons, qui devraient constituer une unique composante connexe.

Notre seconde solution s'affranchit de ces problèmes.

#### 7.3.2 Liquide du système ventriculaire

Contrairement à l'approche précédente, nous n'utilisons pas les différences morphologiques existant entre le système ventriculaire et l'ensemble enveloppe/sillons (nous nous passons donc de l'emploi d'une ouverture), mais nous tirons parti de la localisation centrale dans le cerveau du système ventriculaire qui s'oppose à la localisation périphérique de son enveloppe et de ses sillons.

Décrivons dans un premier temps la segmentation du système ventriculaire :

1. Segmentation du liquide céphalo-rachidien par seuillage bas.

A l'issue d'un seuillage bas de l'image originale (ou du cerveau segmenté), l'objet se compose des éléments de radiométrie sombre : le liquide céphalo-rachidien mais aussi l'air et l'os. Le seuil estimé est :

$$s_3 = \mu_{lcr} + 2\sigma_{lcr},\tag{7.3}$$

où  $\mu_{lcr}$  et  $\sigma_{lcr}$  désignent respectivement la moyenne et l'écart-type du liquide céphalo-rachidien. Si nous avions, comme pour l'approche classique, appliqué un seuillage entre deux valeurs de radiométrie, nous nous serions affranchis de l'air et de l'os, malheureusement au prix de défauts dans la segmentation du liquide, souvent très sombre. La segmentation obtenue ici est donc meilleure, même si l'air et l'os doivent encore être supprimés.

2. Création d'un masque du cerveau.

Nous reprenons ici le masque obtenu lors de la segmentation du cerveau (représenté en (7) sur la figure 7.1). Une érosion morphologique avec une sphère de rayon 1 cm permet de récupérer un objet marquant l'intérieur du cerveau.

3. Suppression de l'air, de l'os et d'une partie des sillons.

Un ET logique appliqué entre le marqueur et l'image segmentée à l'étape 1 permet de ne conserver que les parties profondes des sillons et le système ventriculaire.

Cette opération a deux fonctions : en éliminant l'enveloppe de liquide céphalo-rachidien du cerveau, d'une part elle isole le système ventriculaire de l'ensemble des sillons, et d'autre part, elle garantit que les éléments de sillons restants sont de petite taille.

4. Identification du système ventriculaire.

Il nous suffit maintenant de procéder à un étiquetage de composantes connexes sur l'objet résultant de l'étape précédente pour ne conserver que la composante de plus forte cardinalité. Une fermeture préliminaire garantit que le système ventriculaire est connexe. Cette composante correspond au système ventriculaire, les éléments de sillons constituant une myriade de petites composantes.

Le résultat final est porté sur la figure 7.3.





FIG. 7.3 – Segmentation morphologique du système ventriculaire.

Les images de cette figure illustrent sur la coupe n° 60 de  $xavT_1$  les différentes étapes de la segmentation morphologique du système ventriculaire; l'image numérotée i est le résultat de la  $i^{\text{ème}}$  étape à l'exception de l'image 0, image initiale.

#### 7.3.3 Liquide des sillons

Une fois la segmentation du système ventriculaire menée à bien, il nous faut récupérer l'ensemble enveloppe/sillons.

Nous proposons ici une méthode originale de localisation des sillons préservant leur topologie (connexité et surface d'épaisseur d'un voxel), fondée sur une extension 3D de la ligne de partage des eaux [VINC-91][VINC-92]. A notre connaissance, les seules méthodes qui procurent des résultats similaires sont fondées sur des amincissements homotopiques séquentiels, permettant d'obtenir un squelette surfacique des sillons (voir par exemple [MANG-95]).

1. Paysage radiométrique élevé pour le liquide.

Supposons que la radiométrie soit quantifiée entre  $r_{min}$ , valeur minimale, et  $r_{max}$ , valeur maximale<sup>1</sup>. La radiométrie moyenne  $\mu_{lcr}$  du liquide céphalo-rachidien étant connue, nous pouvons procéder à la transformation affine par morceaux suivante des niveaux radiométriques r des voxels de l'image originale :

 $r = r_{max} - |r - \mu_{lcr}|$ 

Ainsi, à un voxel de radiométrie proche de la radiométrie moyenne du liquide céphalo-rachidien est affecté un niveau élevé ; à l'opposé, plus un voxel possède une radiométrie éloignée de la radiométrie moyenne du liquide céphalo-rachidien, plus son niveau après transformation est bas.

2. Suppression de minima locaux du paysage.

Une fermeture morphologique à l'aide d'une sphère de rayon 1,7 mm est appliquée afin d'éliminer des minima locaux dans l'image de niveaux. Cette opération a pour but de réduire le nombre de bassins versants produits par la prochaine étape.

Augmenter le rayon de l'élément structurant induirait une diminution trop importante du nombre de bassins et nous perdrions des bouts de surface précieux.

3. Calcul de la surface de partage des eaux.

La surface de partage des eaux, développée selon une extension 3D de l'algorithme proposé dans [VINC-91], est calculée à partir de cette dernière image. Cette surface, d'épaisseur un voxel, forme une tesselation de l'espace de l'image où chaque région fermée qu'elle produit, appelée bassin versant, entoure un minimum local de l'image; de plus, cette surface se positionne sur les crêtes du paysage formé par les niveaux de l'image.

Ainsi, de par la construction de l'image produite à l'étape précédente, la surface de partage des eaux suit les sillons. Malheureusement, le caractère de tessellation de cette surface induit un grand nombre d'éléments de surface indésirables.

4. Suppression des éléments de surface appartenant aux substances grise et blanche.

Un ET logique opéré entre l'image binaire de la surface de partage des eaux et l'objet air/os/liquide obtenu comme précédemment (image (1) de la figure 7.3) par un seuillage bas permet de s'affranchir des voxels constitués de substance grise ou blanche :

$$s_4 = \mu_{gris} - \frac{\sigma_{gris}}{2}.$$
 (7.4)

<sup>1.</sup> Si la quantification est de 8bit,  $r_{min} = 0$  et  $r_{max} = 255$ 

Remarquons que le seuil ne doit cependant pas être trop bas afin de conserver les voxels de volume partiel liquide des sillons/cortex. Ainsi, même lorsque l'épaisseur des sillons est faible, la présence d'un sillon peut être identifiée.

5. Suppression des éléments de surface extérieurs.

Nous appliquons de nouveau un opérateur ET logique entre la nouvelle image et le masque du cerveau (image (7) de la figure 7.1); les éléments de surface correspondant à l'air et à l'os sont ainsi éliminés.

6. Ajout de la surface cérébrale.

Un opérateur OU appliqué entre la surface extérieure du cerveau, déduite du masque du cerveau par un extracteur de contour, et l'image précédente permet de constituer l'enveloppe de liquide céphalo-rachidien et de garantir sa topologie de surface.

De plus, la connexion entre cette enveloppe et les éléments de surface correspondant au sillon est effective.

7. Création d'un masque du système ventriculaire.

Une dilation (avec pour élément structurant une sphère de rayon 2 mm) du système ventriculaire déjà segmenté (image (4) de la figure 7.3) nous fournit un masque ou cache.

8. Suppression des éléments de surface ventriculaire.

Les seuls éléments de surface indésirables restants correspondent au système ventriculaire. Grâce au masque construit lors de l'étape précédente, nous retenons uniquement les élements de surface désignant l'enveloppe et les sillons.

9. Nettoyage.

Un étiquetage de composantes connexes nous permet d'éliminer les éléments de surface isolés par les opérateurs successifs que nous avons appliqués, éléments dont l'existence n'a aucune signification anatomique puisque l'ensemble du liquide céphalo-rachidien forme une unique surface.

La figure 7.4 illustre les étapes de cette méthode.

#### 7.3.4 Résultats et discussion

Les résultats obtenus sont généralement bons (voir aussi l'annexe C). Les limites de la méthode proposée et les extensions possibles sont résumées ci-dessous :

- des parties fines des ventricules (dans les troisième et quatrième ventricules) peuvent manquer à cause du volume partiel; ce problème dépend du choix des valeurs de seuil,
- la plus grande composante connexe pour sélectionner les ventricules peut être connectée au LCR du plan inter-hémisphérique; bien que ce problème survienne rarement, une solution pour rendre cette étape complètement robuste passerait par la détection du plan inter-hémisphérique,
- la localisation du LCR des sillons semble très robuste, mais une étape d'ébarbulation peut être nécessaire.



(1)

FIG. 7.4 – Segmentation morphologique de l'enveloppe cérébrale et des sillons.

Les images de cette figure illustrent sur la coupe n° 60 de  $x avT_1$  les différentes étapes de la segmentation morphologique de l'enveloppe et des sillons; l'image numérotée i est le résultat de la  $i^{\text{ème}}$  étape. Notez que l'isolement apparent de parties de sillons est causé par la visualisation bidimensionnelle; en fait, la segmentation obtenue ne représente qu'une unique composante 3D-connexe.

Les problèmes liés au choix des valeurs de seuils et de l'estimation de la moyenne du LCR peuvent être surmontés par une bonne estimation de ces paramètres. La méthode automatique que nous avons utilisée donne de très bons résultats et fournit exactement les même seuils que ceux que nous avions initialement fixés à la main par essais successifs.

Un des avantages de la méthodes utilisant la surface de partage des eaux est qu'elle garantit une bonne localisation de la surface médiane des sillons, souvent meilleure que celle obtenue par le squelette de la réunion des sillons et du cortex [MANG-95], où les surfaces obtenues peuvent être décalées par rapport à la position exacte des sillons.

L'étape suivante serait de segmenter complètement les sillons, à partir de la localisation surfacique obtenue. On peut penser par exemple à des méthodes de croissance de région homotopique.

### 7.4 Segmentation de la substance grise

La substance grise est présente dans le cortex, région périphérique du cerveau située sous l'ensemble enveloppe/sillons baigné de liquide céphalo-rachidien, et dans les noyaux centraux, amas sous-corticaux.

La reconnaissance des structures de substance grise peut être limitée à la distinction cortex/noyaux centraux, ou peut être poussée jusqu'à l'identification des différents noyaux.

#### 7.4.1 Segmentation du cortex

L'originalité de la méthode que nous proposons par rapport aux méthodes traditionnelles de segmentation du cortex consiste en la prise en compte d'une segmentation de l'ensemble enveloppe/sillons déjà existante :

1. Séparation des substances par seuillage.

Un seuillage bas entre les radiométries moyennes des substances grise et blanche fait apparaître l'interface entre ces deux substances :

$$s_5 = \mu_{blanc} - 2\sigma_{blanc}. \tag{7.5}$$

L'objet résultant est constitué de l'air, de l'os, du liquide céphalo-rachidien (ces trois structures étant plus foncées que la substance grise) et de la substance grise.

Nous aurions pu aussi effectuer un seuillage plus sélectif car entre deux valeurs de radiométries (par exemple, pour ne récupérer que le liquide céphalo-rachidien et la substance grise) mais cela n'aurait que très peu changé le processus de la méthode.

2. Régularisation par filtrage médian.

Un filtre médian en 6-connexité élimine le bruit de l'image binaire et lisse les différentes entités. En particulier, la forme du cortex est régularisée.

3. Dilatation de l'ensemble enveloppe/sillons.

Une dilatation de rayon 5 mm est appliquée à l'ensemble enveloppe/sillons (image (9) de la figure 7.4). L'objet résultant définit la région de l'image où la présence du cortex est valide.

En effet, l'épaisseur moyenne du cortex est de 3 mm mais il nous faut considérer les régions où ce dernier est plus épais ainsi que des erreurs éventuelles sur la position des structures enveloppe/sillons dues à l'échantillonnage.

4. Isolement du cortex.

Un opérateur ET est appliqué entre les deux images créées à l'issue des deux étapes précédentes. Le cortex est donc défini par sa proximité à l'enveloppe cérébrale et aux sillons d'une part, et par ses caractéristiques radiométriques d'autre part.

5. Affinement de la segmentation.

Cette segmentation demande à être affinée : jusqu'à présent, nous ne nous sommes pas restreints à la région cérébrale ; de plus, la proximité des sillons au système ventriculaire peut entraîner la présence dans l'objet cortex de certaines parties du système ventriculaire.

Aussi, la segmentation est finalement nettoyée en utilisant, comme nous l'avons déjà fait à plusieurs reprises, le masque du cerveau (image (7) de la figure 7.1) ainsi que le masque du système ventriculaire dilaté (image (7) de la figure 7.4).

Les différentes étapes de cette procédure sont illustrées sur la figure 7.5.





FIG. 7.5 – Segmentation morphologique du cortex.

Les images de cette figure illustrent sur la coupe n° 60 de  $xavT_1$  les différentes étapes de la segmentation morphologique du cortex ; l'image numérotée i est le résultat de la  $i^{\text{ème}}$  étape à l'exception de l'image 0, image initiale.

#### 7.4.2 Segmentation des noyaux centraux

La méthode décrite ci-dessous permet la reconnaissance des noyaux caudés, des putami et des thalami avec la distinction suivant l'hémisphère :

1. Seuillage des noyaux gris.

Un seuillage entre deux valeurs de radiométrie ( $s_3$  et  $s_5$ ) donne une image binaire qui comporte les objets suivants: cortex, peau et noyaux gris. Ces derniers, fortement victimes de bruit et trop proches du cortex, n'apparaissent pas comme des structures facilement isolables dans l'image.

2. Masquage.

Les voxels de l'objet localisés à l'extérieur du cerveau ou au dilaté (par un élément structurant de 1,7 mm) du cortex sont supprimés.

Les voxels restants appartiennent donc aux structures grises de l'aire sous-corticale, c'est-àdire aux noyaux centraux.

3. Régularisation.

Un filtre médian est appliqué avec de réduire le bruit binaire des noyaux. La cohérence de ses structures apparaît alors.

4. Identification par érosion.

Une légère érosion possible (élément structurant de 1,7 mm) est appliquée pour séparer les différents noyaux. Elle est suivie d'un étiquetage qui permet leur reconnaissance grâce à l'examen de leur localisation.

5. Reconstruction.

Afin de récupérer une partie du volume des noyaux perdu lors de l'érosion, nous procédons à une dilation indépendemment pour chaque noyau. Chaque dilatation est menée conditionnellement à l'image issue de l'étape 2; l'élément structurant de ces dilations est de rayon 2 mm.

Les résultats obtenus aux différents étapes sont illustrés sur la figure 7.6.

La reconnaissance des noyaux implique une ouverture qui limite la qualité de la segmentation finale. Comme on peut le constater sur la figure, les noyaux ne sont pas reconstruits complètement ; leur morphologie est trop fine par endroit. Une autre solution pourrait être de séparer les noyaux en appliquant un algorithme de surface des eaux sur la distance des noyaux au fond inversée.

# 7.5 Résultat complet et conclusion

Le résultat complet de nos procédures est reporté sur les planches 7.7 et 7.8. La substance blanche est obtenue simplement comme étant l'ensemble des voxels du cerveau non étiquetés (ni liquide céphalo-rachidien, ni substance grise). La cohérence globale est assurée en imposant des priorités entre les structures détectées. Ainsi le résultat complet s'obtient par superposition des différentes segmentations dans l'ordre suivant : fond, cerveau, noyaux centraux, cortex, sillons, ventricules. Cela permet d'éliminer d'une structure des voxels obtenus également dans la segmentation d'une structure de priorité supérieure.



(0)



FIG. 7.6 – Segmentation morphologique des noyaux centraux.

Les images de cette figure illustrent sur la coupe n° 60 de  $xavT_1$  les différentes étapes de la segmentation morphologique des noyaux centraux ; l'image numérotée i est le résultat de la  $i^{\text{ème}}$  étape à l'exception de l'image 0, image initiale.


FIG. 7.7 – Planche de coupes axiales de l'acquisition  $xavT_1$ 

Cette planche est constituée d'un ensemble de coupes régulièrement espacées, tirée de l'acquisition  $xavT_1$ ; cette planche, une fois segmentée par nos procédures morphologiques, fait l'objet de la planche 7.8.



FIG. 7.8 – Planche de coupes axiales de la segmentation morphologique de  $xavT_1$ 

Cette planche correspond à la planche 7.7 une fois segmentée par nos procédures morphologiques; les structures présentes sont: la région extra-cérébrale (en blanc), la substance blanche (en gris clair), la substance grise (en gris moyen), le liquide céphalo-rachidien (en gris foncé), et le système ventriculaire (en noir).

Dans ce chapitre, nous avons montré comment, à partir de la connaissance des caractéristiques radiométriques des matières présentes dans les IRM, nous pouvions à l'aide de considérations morphologiques segmenter les structures cérébrales importantes :

- cerveau,
- enveloppe cérébrale,
- sillons,
- système ventriculaire,
- cortex,
- noyaux caudés,
- putamen,
- thalami,
- substance blanche.

L'apport de traitements morphologiques appliqués aux résultats des classifications de la partie II est donc manifeste; les images segmentées sont très correctes et la totalité des procédures n'excède pas cinq minutes de traitements sur les machines du haut de gamme actuel.

Nous aurions pu encore affiner certaines procédures : les différents composants du système ventriculaire auraient pu être identifiés ; un bouchage du cortex l'aurait rendu plus cohérent ; il en serait de même pour les noyaux centraux à l'issue de l'étape 3, etc.

Les résultats obtenus pour l'interface gris/blanc sont bons. Cependant la méthode ne garantit pas complètement la topologie de la matière blanche. L'interface cortex/LCR est juste localisée (comme pour les sillons) et non segmentée précisément. Les résultats montrent que les surfaces correspondantes passent par la partie centrale des sillons. Cela est garanti par le fait que ces parties centrales souffrent moins de volume partiel que les bords des sillons, et qu'elles sont donc les lignes de crête de l'image sur laquelle est calculée la surface de partage des eaux. Pour les noyaux centraux, nous obtenons de bons marqueurs, mais la segmentation peut être imprécise sur les bords, en particulier à cause du volume partiel dont souffrent les parties fines. Ces marqueurs constituent un bon point de départ pour des traitements ultérieurs, utilisant par exemple des déformations d'atlas pour la segmentation précise ou pour la reconnaissance individuelle des différents noyaux. Ces aspects seront abordés dans la partie IV.

Notre contribution a pour originalité d'introduire aussi des informations *a priori* sous la forme de considérations spatiales :

- les objets qui nous intéressent sont à l'intérieur du cerveau,
- le système ventriculaire est bien à l'intérieur du cerveau,
- le cortex est localisé à une faible distance de la réunion enveloppe/sillons.

Celles-ci rendent possible des enchaînements de traitements produisant de meilleurs résultats que des enchaînements plus classiques. L'annexe C présente les résultats obtenus sur un jeu d'images variées, constitué dans le cadre d'un projet national.

Toutefois, l'ensemble de ces traitements présente deux défauts principaux.

Tout d'abord, une dépendance importante d'un résultat intermédiaire à l'autre. Ainsi, toutes les segmentations s'appuient sur la première, celle du cerveau ; la segmentation du cortex, sur celle des sillons ; celle des noyaux centraux, sur celle du cortex.

Ensuite, les différents seuils proviennent de la connaissance de caractéristiques radiométriques. Leur utilisation n'est donc pas toujours optimale, surtout lorsque l'on souhaite jouer sur les voxels de mélange pour avoir des objets plus ou moins importants.

Une solution pour s'affranchir de ces défauts pourrait être de procéder à l'ensemble de ces traitements de manière semi-automatique. L'expert pourrait alors contrôler les résultats à l'issue des étapes importantes voire modifier quelquefois à la main ces résultats.

# **Chapitre 8**

# Estimation automatique des caractéristiques des tissus purs

Jusqu'à présent, nous avons estimé les caractéristiques des lois radiométriques gaussiennes des différentes matières cérébrales de deux façons :

- par un apprentissage supervisé en section 2.3,

– grâce à des classifications automatiques au chapitre 5.

La première solution n'est pas acceptable en routine clinique car elle est trop laborieuse.

Quant à la seconde solution, elle nous fournit des caractéristiques en tenant compte de l'effet de volume partiel ce qui induit des différences par rapport à la première solution (Cf. à titre de comparaison les tableaux 5.4 et 2.5). L'évaluation des caractéristiques à partir de l'histogramme est donc biaisée ; pour le liquide céphalo-rachidien par exemple, la loi radiométrique « pure » (montrée en figure 4.2) ne saurait être retrouvée facilement avec le seul examen de l'histogramme de l'image (figure 2.7).

Des méthodes envisageables pour estimer automatiquement les caractéristiques pures peuvent s'appuyer sur les résultats d'une classification automatique préalable.

Les voxels dont les caractéristiques sont proches des centres radiométriques des classes, non seulement sont *a priori* d'appartenance plus sûre à leur classe, mais aussi ne sont pas *a priori* des voxels de mélange. Ainsi, une mesure statistique des individus de caractéristiques proches d'un centre de classe peut nous renseigner sur l'aspect de la loi radiométrique de la classe.

Les deux problèmes posés par cette approche sont que la sélection d'individus biaise les statistiques obtenues, et que la localisation des individus/voxels dans l'image n'est pas prise en compte. Pourtant, ce sont ces informations contextuelles qui pourraient nous aider à distinguer les voxels purs des voxels de mélange.

Dans ce chapitre, nous proposons une méthode originale d'estimation des caractéristiques radiométriques des matières cérébrales pures, prenant en compte ce type d'informations contextuelles [GERA-95b]. Cette méthode, qui peut être mise en œuvre à partir d'une première segmentation grossière de ces matières, permet, par l'intégration d'informations contextuelles, d'écarter les voxels de mélange afin d'évaluer les caractéristiques radiométriques des classes pures. La méthode s'appuie sur une caractérisation des voxels de mélange en fonction de leur localisation (section 8.1). Nous introduisons la notion d'interface entre deux régions (section 8.2), qui permet de définir les zones susceptibles de contenir des voxels de mélange entre ces deux régions. Nous présentons enfin la procédure d'estimation (section 8.3).

Cette méthode a été appliquée à des images par résonance magnétique de cerveaux d'enfants atteints d'adrénoleukodystrophie; ces images, très anisotropes, présentent un très fort effet de volume partiel, et malgré cet effet, les estimations statistiques obtenues par notre méthode se sont avérées très robustes [AURD-97].

# 8.1 Caractérisation des voxels de mélange en fonction de leur localisation

La caractérisation que nous exposons ici s'appuie sur une constatation que nous avons faite à l'issue du protocole d'apprentissage supervisé des statistiques radiométriques des matières cérébrales en section 2.3.2.

## 8.1.1 Localisation des voxels sûrs et purs

Dans ce protocole, nous déterminions manuellement dans les trois plans de coupe les voxels d'une matière donnée, et nous ne conservions au final que les voxels désignés à trois reprises, afin d'éliminer de l'ensemble d'apprentissage les voxels dont l'appartenance à cette matière n'est pas certaine.

Cela nous a permis d'observer que les voxels conservés pour l'apprentissage se trouvent en grande majorité, d'un point de vue spatial, bien à l'intérieur des structures cérébrales, et les voxels dont l'appartenance à une structure n'est pas très sûre sont les points de la périphérie de cette structure.

Cette observation s'interprète très simplement : l'appréciation du positionnement d'une frontière est délicate car les voxels frontaliers sont la plupart du temps des voxels de mélange (Cf. figure 2.12). A partir d'une segmentation même grossière des matières cérébrales, nous pouvons alors distinguer les voxels dont l'appartenance à leur classe est sûre, parce qu'ils sont localisés profondément dans leur région, de ceux dont l'appartenance est douteuse, parce qu'ils sont trop périphériques.

Lorsqu'une région issue de classification est cohérente spatialement, le degré d'appartenance d'un voxel à une classe doit être d'autant plus élevé qu'il est éloigné de la frontière de cette classe dans l'image.

## 8.1.2 Localisation des voxels de mélange

Un raisonnement similaire permet de déterminer, pour les voxels de mélange, quelle sont les autres classes du mélange.

Nous ne considérons toujours pas les caractéristiques de ce voxel (son vecteur radiométrique), mais sa localisation spatiale dans l'image. La classe qui semble la meilleure candidate pour participer au mélange est celle qui est la plus proche de lui dans l'image.

En effet, un voxel peu sûr étant sur le bord d'une région, son appartenance à la région voisine fait partie de l'alternative la plus probable. Les voxels de mélange sont précisément dans cette situation.

Afin d'estimer l'effet de volume partiel que peut subir un voxel, deux paramètres entrent en compte :

- sa distance à la surface de sa région,
- la région à laquelle il n'appartient pas et dont il est le plus proche.

Une segmentation grossière étant donnée, il est raisonnable d'affirmer que nous aurons plus de voxels de mélange lorsque leurs distances à la surface de sa région diminuent.

De plus, toujours lorsque la distance diminue, la contribution de la classe de ce voxel au mélange diminue elle aussi, selon toute vraisemblance; et la contribution qui augmente dans le mélange est celle de la classe de la région la plus proche du voxel.

Partant de ces considérations, nous proposons ici une façon de visualiser l'effet de volume partiel en suivant l'évolution de la radiométrie de l'image en fonction de la distance à la frontière commune à deux régions.

# 8.2 Carte de plus proche région et interfaces

Afin d'évaluer les deux paramètres qui entrent en compte dans l'estimation du volume partiel, nous proposons ici, à partir d'une segmentation grossière issue d'une classification, de calculer simultanément une carte de distance aux frontières des régions, ainsi qu'une carte de la plus proche région. Ce calcul est réalisé par une modification de l'algorithme de propagation de distances par chanfrein [BORG-86].

## 8.2.1 Procédure d'obtention des interfaces

Notons (x, y, z) le jeu de coordonnées d'un voxel, S(x, y, z) sa valeur dans une image S, R l'image des régions, D la carte de distance, PPR la carte de la plus proche région,  $Ch^{forth}$  et  $Ch^{back}$  les deux demi-chanfreins, l un indice de voisinage dans le chanfrein,  $ch_l$  le coefficient de chanfrein qui lui est associé dans Ch, et  $(x_l, y_l, z_l)$  les coordonnées du  $l^{\text{ème}}$  voisin du voxel de coordonnées (x, y, z). L'algorithme de calcul de la carte de plus proches voisins est donné dans le tableau 8.1. Le principe consiste simplement à propager, en même temps que les distances, la classe du voxel le plus proche.

Le résultat de cet algorithme est illustré par la figure 8.1. L'image initiale simule une segmentation en trois classes : noir pour le fond, gris foncé pour une portion de disque, et gris clair pour un carré.

Si cette image avait une moins bonne résolution, l'effet de volume partiel serait présent aux frontières { noir/gris foncé }, { gris foncé/gris clair }, et { gris clair/noir }; à chaque frontière distincte, l'effet se traduirait différemment car le couple de régions concernées n'est jamais le même.

A l'aide de l'image originale et de la carte de la région la plus proche, il est possible de définir ces différentes frontières, et mieux, les différentes interfaces correspondantes. Nous appelons « interface » une zone d'influence entre deux régions adjacentes, comprenant les voxels susceptibles d'être de mélange des deux matières correspondantes; nous pouvons définir une interface entre la région d'étiquette *a* et celle d'étiquette *b* par l'ensemble des points de coordonnées (x, y, z) qui vérifient :

$$(R(x, y, z) = a \text{ et } PPR(x, y, z) = b) \text{ ou } (R(x, y, z) = b \text{ et } PPR(x, y, z) = a)$$

Un point appartient ainsi à l'interface entre deux régions s'il fait partie d'une de ces deux régions, et si l'autre région est la plus proche région, la sienne mise à part.



FIG. 8.1 – Procédure d'évaluation de l'effet de volume partiel

Cette simulation montre les traitements qui sont appliqués à une image de régions (en haut à gauche) pour évaluer l'effet de volume partiel. Une carte de distance aux frontières des régions est calculée (en haut à droite) simultanément à une carte de la plus proche région (en bas à gauche). Dans cette dernière carte par exemple, les points noirs de la partie carré correspondent aux points du carré dont la région la plus proche est la région noire. La complémentarité de ces trois informations permet d'obtenir la description des interfaces entre les régions originales, description illustrée par l'image en bas à droite. Dans cette image, les trois interfaces (ou zones d'influence) résultantes sont délimitées par une ligne continue blanche ; ce sont : l'interface { noir/gris foncé } (partie supérieure gauche de l'image), l'interface { gris foncé/gris clair } (partie centrale), et l'interface { gris clair/noir } (partie inférieure droite). La frontière entre les deux régions participant à une interface est représentée par une ligne discontinue, et la distance à cette frontière au sein d'une interface, en dégradé de gris.

TAB. 8.1 – Algorithme de calcul d'une carte de la plus proche région

pour tout (x, y, z) faire
si le voxel de coordonnées (x, y, z) est sur la surface d'une région et si R(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>) est la valeur la plus représentée dans son voisinage
alors D(x, y, z) = 0 et PPR(x, y, z) = R(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>)
sinon D(x, y, z) = +∞
pour tout (x, y, z) pris dans l'ordre faire
pour tout l dans Ch<sup>forth</sup> faire
si D(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>) + ch<sub>1</sub> < D(x, y, z) faire</li>
D(x, y, z) = D(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>) + ch<sub>1</sub>
PPR(x, y, z) = PPR(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>)
pour tout (x, y, z) hors surface pris dans l'ordre inverse faire
pour tout l dans Ch<sup>back</sup> faire
si D(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>) + ch<sub>1</sub> < D(x, y, z) faire</li>
D(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>) + ch<sub>1</sub> < D(x, y, z) faire</li>
PPR(x, y, z) = D(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>) + ch<sub>1</sub>
PPR(x, y, z) = PPR(x<sub>1</sub>, y<sub>1</sub>, z<sub>1</sub>)

De plus, dans cette interface, chaque point connaît sa distance D(x, y, z) à la frontière entre les deux régions. Nous pouvons signer cette distance pour distinguer dans l'interface les deux régions de part et d'autre de la frontière ; par exemple, formons D' suivant :

$$D'(x, y, z) = \begin{cases} D(x, y, z) & \text{si } R(x, y, z) = a \\ -D(x, y, z) & \text{si } R(x, y, z) = b \end{cases}.$$

L'image en bas à droite de la figure 8.1 montre les trois interfaces résultantes (de contour blanc), leur frontière respective (de contour discontinu blanc), et la distance aux frontières (en dégradé de gris).

# 8.2.2 Application à une classification en IRM

Cette procédure a été menée sur une segmentation de l'acquisition  $x av T_1$  issue d'une classification par l'algorithme des k-moyennes; les quatre classes présentes sont le fond, le liquide céphalorachidien, la substance grise, et la substance blanche. Cette segmentation est représentée par la coupe (a0) de la figure 8.2. Sur cette même figure se trouvent, en (b0) la carte de la plus proche région, et en (c0) l'interface { liquide céphalo-rachidien/substance grise }.

Afin d'évaluer la sensibilité de cette procédure à la forme de la segmentation initiale, nous avons appliqué à celle-ci des filtrages médians avec un voisinage de taille croissante. Les résultats font l'objet des images de la colonne de droite de la figure 8.2 pour le 6-voisinage, et des colonnes de la figure 8.3, celle de gauche pour le 18-voisinage et celle de droite pour le 26-voisinage.

La régularisation lisse les régions initiales et supprime le bruit, mais aussi fait disparaître de trop petites régions. En conséquence, la carte de la région la plus proche et les interfaces finales sont elles aussi régularisées.

# 8.3 Estimation des voxels de mélange

Au sein d'une interface, nous pouvons établir l'évolution de la radiométrie en fonction de la distance D' à la frontière de cette interface.

# 8.3.1 Obtention de la radiométrie des tissus purs

Chaque distance a une valeur discrète dans la carte de distance; pour chaque valeur discrète de distance, nous pouvons donc estimer la radiométrie moyenne, et cela pour toute interface indépendamment d'une autre.

L'évolution de la radiométrie moyenne en fonction de la distance est montrée en trait plein dans les deux schémas de la figure 8.4. Elle a été calculée à partir de la classification non régularisée montrée sur l'image (a0) de la figure 8.2; les calculs ont été menés en 3D, en tenant compte dans le chanfrein de l'anisotropie de l'acquisition IRM. Le schéma du haut est dédié à l'interface entre le liquide céphalo-rachidien et la substance grise (cette interface est montrée sur l'image (c0) de la figure 8.2); celui du bas, à l'interface entre la substance grise et la substance blanche.

Les saccades de la moyenne radiométrique, observées lorsque la distance est élevée en valeur absolue, s'expliquent par le faible nombre de voxels pris en compte dans le calcul. Ce nombre de voxels est représenté en pointillé, avec un facteur de réduction de 10 000, et avec le zéro rapporté en bas des schémas. Comme nous pouvons le constater, la masse importante des voxels d'une région sont des voxels surfaciques, donc potentiellement sujets à l'effet de volume partiel ; seule la substance blanche, très volumineuse, comporte un nombre relativement élevé de voxels éloignés de sa surface (*nota bene* : l'échelle des distances n'est pas la même sur les deux schémas).

Les courbes des moyennes radiométriques forment des plateaux lorsque la distance est suffisamment grande en valeur absolue; les voxels pris en compte pour ces moyennes sont des voxels d'appartenance plutôt sûre à leur classe, et sont *a priori* dénués de mélange. Ce sont donc de bons candidats pour évaluer la radiométrie des classes « pures ».

Les courbes discontinues donnent la moyenne radiométrique cumulée suivant les distances croissantes en valeurs absolues ; pour les distances élevées, nous retrouvons donc la moyenne des classes. L'écart entre ces courbes et les courbes de moyennes non cumulées est dû à la quantité de voxels proches des frontières ; ces points « douteux » faussent les estimations statistiques.

Une information qui se déduit de l'observation des courbes de moyenne et de moyenne cumulée concerne la qualité de localisation de la frontière. Dans le schéma de l'interface entre la substance grise et la substance blanche, en bas sur la figure 8.4, l'écart entre les deux courbes est similaire de part et d'autre de la distance nulle, donc de la frontière. Cela signifie que les voxels de mélange sont répartis à égalité dans les deux classes représentées. En revanche, dans le schéma du haut de cette même figure, ce n'est pas le cas. L'écart est beaucoup plus important du côté du liquide céphalorachidien que du côté de la substance grise; à l'issue de la classification par l'algorithme des *k*-moyennes, les voxels de mélange sont donc plus nombreux dans la classe liquide céphalo-rachidien que dans la classe substance grise. La cause de cela est que le volume des sillons est surestimé.

Afin d'obtenir des statistiques radiométriques robustes, nous devons laisser de côté les voxels trop proches de frontières. Nous proposons donc d'éroder les régions de la segmentation initiale jusqu'à



(a0)



(a6)





FIG. 8.2 – Régions d'étude de l'effet de volume partiel

Ces images (a), (b) et (c) représentent respectivement une classification obtenue par seuillage, la carte de la plus proche classe, et l'interface entre liquide céphalorachidien et substance grise (intérieur de la région délimitée par les lignes blanches). Sur cette dernière image, l'interface entre substance grise et substance blanche est le complémentaire, à l'intérieur du cerveau, de la première interface. La colonne de gauche correspond à un traitement de la



(a26)





FIG. 8.3 – Régions d'étude de l'effet de volume partiel (suite)

Ces images (a), (b) et (c) représentent respectivement une classification obtenue par seuillage, la carte de la plus proche classe, et l'interface entre liquide céphalorachidien et substance grise. Sur cette dernière image, l'interface entre substance grise et substance blanche est le complémentaire, à l'intérieur du cerveau, de la première interface.



FIG. 8.4 – Evolution de la moyenne radiométrique dans les interfaces entre matières

Ces schémas représentent, pour une interface donnée entre deux régions, l'évolution (en trait plein) de la moyenne radiométrique dans l'image en fonction de la distance à la frontière commune de ces régions ; l'évolution de la moyenne radiométrique cumulée à partir de la frontière est donnée en trait discontinu ; enfin, en pointillé apparaît le nombre de voxels pris en compte dans ces moyennes (le 0 du nombre de voxels est positionné en bas des schémas, et ce nombre est représenté avec un facteur de réduction de 10 000). Prenons un exemple pour l'interface entre le liquide céphalorachidien et la substance grise (schéma du haut). Les voxels de distance -1 mm dans cette interface appartiennent à la classe LCR, et sont situés à 1 mm de la frontière séparatrice entre LCR et SGR. Dans l'image, ils sont approximativement au nombre de 100 000 (la courbe en pointillé indique 20 en ordonnée, et l'ordonnée origine est 10, d'où  $(20 - 10) \times 10\ 000 = 100\ 000$ ). La moyenne radiométrique de ces voxels est 30 (courbe continue), et la moyenne cumulée (courbe discontinue) est 35 ; cette dernière moyenne prend en compte tous les voxels de classe LCR et de distance inférieure ou égale à 1 mm ; elle est donc biaisée par les volumes partiels.

atteindre les zones radiométriquement stables; l'estimation des statistiques des matières cérébrales est alors restreinte à l'intérieur des régions. Les résultats sont regroupés dans le tableau 8.2.

matière	nb.voxels	moyenne	écart-type	asymétrie	aplatissement				
régions non érodées									
LCR	287 799	32.1	10.2	-0.48	2.30				
SGR	586 454	58.1	5.9	-0.09	1.96				
SBL	536 754	78.1	6.2	2.27	30.89				
régions érodées de 1 mm									
LCR	97 765	25.8	8.5	0.07	2.50				
SGR	229 111	57.5	4.8	0.00	2.36				
SBL	337 215	80.2	5.4	2.46	44.82				
régions érodées de 2 mm									
LCR	11 768	23.7	7.3	0.31	2.95				
SGR	8 029	57.0	4.6	0.08	2.43				
SBL	157 589	80.6	4.8	0.37	3.37				
régions érodées de 3 mm									
LCR	1600	22.6	6.4	0.35	3.26				
SGR	152	58.3	4.4	-0.22	2.43				
SBL	83 838	81.1	4.8	0.37	3.32				

TAB. 8.2 – Statistiques obtenues sur les régions érodées issues d'une classification

Nous pouvons observer qu'à partir d'une érosion de 2 mm, les asymétries et aplatissements témoignent effectivement de lois radiométriques gaussiennes (pour ces lois, les valeurs théoriques de ces coefficients sont respectivement 0 et 3). Une érosion de 1 mm est insuffisante à cause de l'épaisseur de 1,3 mm des coupes axiales de l'acquisition utilisée  $(xavT_1)$ ; une telle érosion se limite donc au plan de coupe axial, et ne supprime pas une part importante des voxels de mélange. Enfin, si l'érosion est trop forte pour une région peu volumineuse, le nombre de voxels intervenants dans le calcul des statistiques est trop faible, et ces dernières ne sont pas significatives (c'est le cas de la substance grise avec une érosion de 3 mm).

Pour l'ensemble de ces raisons, nous avons choisi de conserver les résultats donnés par une érosion de 2 mm pour la substance grise, et de 3 mm pour le liquide céphalo-rachidien et pour la substance blanche.

Le tableau 8.3 compare la moyenne des lois radiométriques de trois classes (liquide céphalorachidien, substance grise, et substance blanche) obtenues par différentes méthodes :

- l'apprentissage supervisé de la section 2.3,
- l'algorithme des k-moyennes de la section 5.2,
- l'apprentissage de fonctions d'appartenance floue de la section 5.4,
- l'érosion d'une segmentation grossière de cette section.

Pour le liquide céphalo-rachidien, l'érosion de cette dernière méthode permet d'obtenir un résultat plus proche de l'apprentissage que les autres méthodes, en s'affranchissant partiellement des nombreux voxels de mélange présents dans les sillons corticaux. Pour la substance grise, les méthodes automatiques sont d'accord pour remettre en cause les statistiques de l'apprentissage supervisé; ce dernier a été mené sur des noyaux, dont les radiométries diffèrent légèrement entre elles et avec celle du cortex, beaucoup plus foncée. Ces méthodes nous fournissent donc un résultat intermédiaire.

Pour la substance blanche, les trois résultats automatiques sont équivalents, avec un léger avantage pour la méthode de cette section.

classe	apprentissage	k-moyennes	histogramme	érosion
liquide céphalo-rachidien	16.0	32.0	27.9	22.6
substance grise	64.1	58.1	57.7	57.0
substance blanche	79.8	78.1	76.6	81.1

TAB. 8.3 – Comparaison des moyennes des matières obtenues par différentes méthodes

La robustesse de la méthode présentée dans cette section vis-à-vis de la segmentation initiale peut paraître douteuse. En effet, puisqu'elle s'appuie sur des frontières entre régions et sur des interfaces d'influence, elle peut sembler très sensible au bruit. Néanmoins, ses résultats sont bons, mais nous sommes en droit de nous demander s'ils le seraient autant en présence de plus de bruit de classification.

Nous avons proposé en section 8.2.2 un remède préventif sous la forme d'une régularisation initiale, effectuée avant le calcul des cartes de distance et de plus proche région. Nous devons encore vérifier que les résultats restent stables malgré une régularisation.

La figure 8.5 illustre les modifications entraînées par des régularisations de la segmentation initiale. Nous notons dans le plat des courbes des écarts maximaux de 4, 3 et 2 niveaux radiométriques pour respectivement, le liquide céphalo-rachidien, la substance grise et la subtance blanche ; ces écarts restent donc relativement faibles. L'estimation des moyennes radiométriques des matières étant effectuée après érosion, le tableau 8.4 présente les moyennes obtenues au final. Que le filtrage médian soit faible avec un 6-voisinage, ou plus fort avec un 26-voisinage, les résultats conservent une stabilité remarquable ; de plus, les asymétries et aplatissements, qui témoignent des lois radiométriques, sont eux aussi très stables. Les voxels participant aux statistiques témoignent toujours de lois gaussiennes ; les régularisations n'introduisent donc pas une quantité significative de voxels de mélange.

#### 8.3.2 Application à la volumétrie d'une pathologie

Cette méthode a été appliquée à des images par résonance magnétique de cerveaux d'enfants atteints d'adrénoleukodystrophie (Cf. figure 8.6) [ADAM-91]. La particularité de ces images provient d'une très forte anisotropie, les voxels ayant pour résolution 1 mm  $\times$  1 mm dans le plan de coupe axial, et une épaisseur de coupe d'environ 3 mm. Malgré cet effet, les estimations statistiques obtenues par notre méthode se sont avérées très robustes au calcul du volume de la pathologie [GERA-95b][AURD-97].

La figure 8.7 illustre l'obtention des deux interfaces { ALD/ventricules latéraux } et { ALD/cerveau }. Grâce à notre méthode, l'estimation de la quantité de pathologie présente dans les voxels est traitée différemment d'une interface à l'autre.

Pour cela, nous procédons tout d'abord, pour chacune des deux interfaces, à l'obtention de l'évolution des vecteurs radiométriques moyens en fonction de la distance à la frontière de l'interface.



FIG. 8.5 – Modification de l'évolution des radiométries en cas de régularisation initiale

Ces deux schémas montrent les modifications entraînées par des régularisations de la segmentation initiale (imagées en figures 8.2 et 8.3); les deux courbes de référence de la figure 8.4 (sans régularisation) y sont reportées.

TAB. 8.4 – Comparaison des moyennes des matières obtenues par différentes méthodes

matière	nb.voxels	moyenne	écart-type	asymétrie	aplatissement			
sans médian								
LCR	1600	22.6	6.4	0.35	3.26			
SGR	8 029	57.0	4.6	0.08	2.43			
SBL	83 838	81.1	4.8	0.37	3.32			
avec médian sur 6-voisinage								
LCR	5 709	26.1	9.1	0.74	3.60			
SGR	56 326	59.0	6.2	0.06	2.78			
SBL	108 638	80.4	5.0	0.28	3.32			
avec médian sur 18-voisinage								
LCR	6 197	26.8	9.6	0.75	3.53			
SGR	116 537	57.8	7.1	0.02	3.15			
SBL	138 215	80.0	5.2	0.15	3.37			
avec médian sur 26-voisinage								
LCR	6 828	27.3	10.0	0.72	3.36			
SGR	145 131	57.5	7.5	-0.01	3.51			
SBL	146 662	79.8	5.3	0.11	3.38			

Comme nous disposons de deux acquisitions, ces vecteurs radiométriques moyens sont bidimensionnels.

Du fait de la forte anisotropie des acquisitions, et conséquemment, du faible nombre de voxels de la pathologie, l'estimation du vecteur radiométrique moyen de la pathologie ne peut se faire par érosion ; en effet, une érosion faible se traduirait par des érosions restreintes au plan de coupe, et une érosion trop forte serait bien tridimensionnelle, mais ne conserverait pas assez de voxels pour donner des statistiques fiables. Nous utilisons donc l'évolution des radiométries pour lire ces dernières dans les plateaux radiométriques stables, distants des frontières.

Enfin, pour chaque interface, nous établissons la correspondance entre vecteur radiométrique et



FIG. 8.6 – Coupe épaisse extraite de deux acquisitions de modalités différentes

Les volumes, dont une même coupe est extraite ici, ont été acquis en  $T_1$  (à gauche), et en  $T_2$  (à droite); la pathologie se devine à peine sur la première acquisition, mais apparaît plus clairement sur la seconde (zone blanche).

pourcentage de pathologie. Cette correspondance est approximative : nous supposons que le vecteur radiométrique est bilinéaire en fonction du taux de mélange. Le mélange qui intervient dans l'interface { ALD/ventricules latéraux } fait intervenir les vecteurs radiométriques moyens de la pathologie et des ventricules, tandis que le mélange de l'interface { ALD/cerveau } fait intervenir ceux de la pathologie et des ventricules. L'estimation du pourcentage de pathologie est calculée pour chaque voxel des deux interfaces ; elle est donc contextuelle.

La figure 8.8 illustre les résultats obtenus. Finalement, le volume pathologique est déterminé par simple addition des volumes des voxels, volumes pondérés par le pourcentage de pathologie.

# 8.4 Conclusion

Dans ce chapitre, nous avons proposé une méthode automatique d'estimation des caractéristiques des tissus purs, à partir d'une segmentation grossière. L'originalité de la méthode proposée vient de son caractère contextuel, via la notion « d'interfaces » (ou zones d'influence entre deux structures), permettant de déterminer automatiquement les tissus susceptibles d'intervenir dans la composition d'un voxel.

Nous avons montré qu'une segmentation grossière suffit pour que les estimations soient correctes. Si la segmentation est bruitée, une régularisation peut être réalisée ; les estimations radiométriques des régions suffisamment volumiques n'en seront pas affectées, seules les régions d'allures plutôt surfaciques verront leur estimations légèrement modifiées.

Cette méthode ne se limite pas à l'estimation des radiométries moyennes. Avec le partitionnement de l'image en interfaces, et la connaissance des distances à la frontière des régions, elle permet d'évaluer la constitution des voxels de mélange. Nous avons montré l'intérêt de cette évaluation sur une application concrète, un calcul volumétrique de pathologie dans des images fortement anisotropes.

Cette méthode peut être systématisée dans une procédure de segmentation précise. En effet, il



(a)

(b)



(c)

FIG. 8.7 – Définition des interfaces dans lesquelles intervient la pathologie

L'image (a) présente la segmentation initiale, limitée aux objets cérébraux d'intérêt : la pathologie (en blanc), les ventricules latéraux (en gris clair), le reste du cerveau (en gris foncé), et le fond (en noir). L'image (b) est la carte de plus proche région, déduite de l'image (a). Les deux interfaces auxquelles participe la pathologie sont indiquées dans l'image (c) en superposition de l'acquisition en  $T_2$ . Quatre régions d'intérêt ont donc été définies : la région 1 du cerveau proche de la pathologie, la région 2 de la pathologie proche du cerveau, la région 3 de la pathologie proche des ventricules, et la région 4 des ventricules proche de la pathologie.

suffit de disposer d'une segmentation grossière pour estimer les caractéristiques des régions, puis reclassifier les voxels proches des frontières de ces régions.



FIG. 8.8 – Image du pourcentage de pathologie

La partie supérieure des images est extraite de plusieurs coupes successives de l'acquisition en  $T_2$ , et montre les différences morphologiques importantes de la pathologie d'une coupe à l'autre; la partie inférieure correspondante illustre le pourcentage de pathologie de chaque voxel, par un niveau de gris qui lui est proportionnel (0 % de pathologie donne du noir, 100 % du blanc).

# Conclusion

Cette partie avait pour but d'introduire sous différentes formes la notion de contexte spatial dans les méthodes de classification, afin de pallier les limites des méthodes vues en partie II.

Le chapitre 6 est dédié aux champs de Markov, extension contextuelle des classifications bayésiennes vues en partie II. Nous avons tout d'abord comparé les classifications markoviennes voxéliques avec d'autres méthodes de classifications contextuelles; nous avons constaté les bons résultats des classifications locales, pour la segmentation du liquide céphalo-rachidien, de la substance grise, et de la substance blanche. Ces classifications, rarement utilisées dans la littérature, s'avèrent donc de bons outils de classification avec régularisation, lorsqu'il s'agit de segmenter les matières cérébrales principales (figure 6.3 page 133).

Pour la relaxation markovienne, nous avons introduit des termes d'énergie de localisation (page 130 et suivantes); ils nous ont permis d'obtenir un résultat, à notre connaissance original dans le cadre markovien: une classification où la substance grise est caractérisée par deux classes, une pour le cortex, et une pour les noyaux centraux (figure 6.9).

Les méthodes classiques de segmentation sur graphes de régions sont des approches par fusion de régions ([PAVL-77][MONG-87][MAES-95] par exemple) ; les relaxations markoviennes sur ces graphes sont très récentes ([KIM-93][KIM-94]), et peu employées en imagerie cérébrale. Nous avons développé une méthode de relaxation markovienne sur un graphe déduit de la surface de partage des eaux [GERA-95a] (section 6.4.3). Nous avons montré comment cette méthode permettait d'introduire une forte régularisation spatiale à faible coût ; nous en avons mis aussi en évidence les limites, lorsque de petites structures sont à prendre en compte.

Dans le chapitre 7, dédié à la morphologie mathématique, les informations contextuelles ont été introduites implicitement par l'enchaînement des traitements, et en particulier, par l'utilisation d'opérations géodésiques et le choix de la taille des éléments structurants. La connaissance de ces informations provient de la partie I, et les seuils utilisés, de l'apprentissage automatique décrit dans la section 5.4 de la partie II.

Contrairement aux méthodes de classification, chaque structure est traitée individuellement. La dépendance d'une procédure de segmentation d'une structure aux procédures antérieures permet de mener assez loin la reconnaissance des structures, mais présente l'inconvénient d'avoir un effet catastrophique en cas d'échec d'une procédure. Néanmoins, les procédures morphologiques présentées se sont avérées très robustes, comme en témoignent l'annexe C et leur utilisation dans le cadre d'un projet de recherche national.

Parmi les originalités de ces procédures, citons l'utilisation de l'algorithme de la surface de partage des eaux pour la segmentation des sillons (section 7.3.3). Le chapitre 8 propose une méthode contextuelle originale d'estimation des caractéristiques des tissus purs. Le fait de s'affranchir des voxels périphériques des régions issues d'une segmentation grossière, donne des estimations plus précises que les méthodes automatiques non contextuelles de la partie II (tableau 8.3).

En introduction de cette partie, nous avons dit que nous utiliserions deux aspects de la notion de contexte spatial : le voisinage et la position relative. Ces deux aspects se retrouvent dans les approches markoviennes et morphologiques, mais leur mode d'introduction est différent.

Pour l'aspect de voisinage, l'approche markovienne s'appuie sur des cliques, tandis que l'approche morphologique s'appuie sur des éléments structurants.

Pour l'aspect lié à la position relative, l'approche markovienne associe aux cliques des potentiels énergétiques qui permettent de favoriser certaines adjacences, ou au contraire d'en défavoriser; cette approche permet aussi d'influencer la classification grâce à des potentiels de localisation spatiale. Quant à l'approche morphologique, l'information de position relative est imposée par des opérations géodésiques sur des objets connus de l'image, et la force de ces opérations est paramétrable par la taille des éléments structurants.

Les résultats de segmentation témoignent de ces différences.

Avec l'approche markovienne (figure 6.10 page 141), les sillons corticaux sont partiellement effacés, mais les noyaux centraux sont bien plus cohérents qu'avec l'approche morphologique (figure 7.8 page 172). Avec celle-ci, les ventricules et les sillons sont distingués, et les différents noyaux sont marqués ; de plus, les sillons forment une unique composante d'un voxel d'épaisseur. Enfin, l'interface { substance grise/substance blanche } est donnée correctement par les deux approches.

Le niveau de segmentation est donc légèrement en faveur des méthodes de morphologie mathématique, qui poussent un peu plus loin la reconnaissance des structures cérébrales.

Dans cette partie, nous avons quelquefois mis l'accent sur des solutions algorithmiques.

Pour les relaxations markoviennes, nous avons mis en évidence des problèmes de biais, dus à la disproportion entre le nombre de sites et la taille de la table de nombres aléatoires utilisée; nous suggérons l'emploi d'une permutation pour l'accès à ces nombres, afin de réduire ce biais (section B.3).

Pour les traitements morphologiques, nous tenons compte de l'anisotropie de l'image grâce au calcul de cartes de distance. De plus, pour l'obtention d'une carte de la région la plus proche, nous avons étendu l'algorithme de propagation de distances à la propagation d'étiquettes (tableau 8.1).

L'examen des méthodes contextuelles dans cette partie donne lieu à de nombreuses perspectives.

Pour définir les fonctions de potentiel de localisation dans les régularisations markoviennes (section 6.2.4), nous suggérons l'utilisation d'un atlas probabiliste, après que ce dernier a été mis en correspondance avec l'image du cerveau du patient.

Dans le cadre de la relaxation markovienne sur graphe de régions, nous avons proposé une méthode originale de construction d'un graphe, à partir de la surface de partage des eaux ; la classification des sites du graphe est alors telle que tout voxel de l'image est classifié, et telle que les structures surfaciques ne disparaissent pas (section 6.4.4). Il reste donc à définir les termes énergétiques associés aux cliques du graphe.

Pour les procédures de segmentation par morphologie mathématique, les seuillages initiaux pourraient être contextuels locaux ; la régularisation induite dans les images binaires améliorerait la robustesse des traitements ultérieurs. De plus, si l'acquisition était elle-même régularisée, nous pourrions manipuler les opérateurs géodésiques sur les images de radiométries au lieu de se restreindre aux image binaires. Enfin, ces procédures pourraient être étendues aux acquisitions multiples, telles que celles qui ont été utilisées dans la partie II.

Cette partie témoigne donc de la diversité des techniques qui permettent de prendre en compte des informations contextuelles, et nous avons proposé pour chaque technique des méthodes originales. Nous proposons dans la partie IV de mettre en œuvre une procédure de reconnaissance, dans laquelle une grande part de ces techniques seront utilisées.

Quatrième partie

# Reconnaissance progressive par mise en correspondance avec un atlas et fusion floue d'informations structurelles

# Introduction

Dans les parties précédentes de ce manuscrit, les résultats que nous obtenons s'avèrent de qualité insuffisante.

- Les classifications automatiques (partie II) ne prennent en compte que des informations de type radiométrique, et donnent des résultats encourageants, mais sans garantir la cohérence spatiale dans l'image des différents objets cérébraux issus des classes.
- Des informations contextuelles (partie III), introduites de façon globale pour contraindre la cohérence des classes dans l'image à l'aide des énergies de cliques Markoviennes, ne sont pas bien appropriées aux caractéristiques individuelles des structures cérébrales.
- Les segmentations issues de traitements morphologiques (partie III) nous fournissent des résultats cohérents car ces traitements introduisent explicitement des informations *a priori*; en revanche, chaque structure fait l'objet d'un traitement particulier, et les résultats souffrent de l'absence d'un formalisme général qui permettrait de gérer, de la même façon pour toutes les structures, un ensemble plus important d'informations.

Le but de cette dernière partie est de définir un tel formalisme, en tirant le meilleur parti de l'expérience acquise lors de la mise en œuvre des méthodes précédentes.

Après un état de l'art des méthodes qui s'appuient sur un atlas (chapitre 9), nous décrivons de façon générale une procédure de reconnaissance originale, progressive et guidée par une mise en correspondance avec un atlas et par la fusion floue d'informations structurelles (chapitre 10). L'originalité de cette procédure de reconnaissance est multiple.

- D'une part, nous proposons une méthode originale pour la prise en compte d'informations structurelles sous la forme de contraintes spatiales flexibles, dont le formalisme s'appuie sur la théorie des ensembles flous et de la fusion d'informations. Les méthodes de segmentation proposées précédemment sont alors utilisées non plus globalement, mais sous des contraintes, donc conditionnellement à une région d'intérêt de limites imprécises.
- D'autre part, la méthode de mise en correspondance entre volume IRM et atlas que nous proposons permet d'inférer un champ de déformation discret respectant les contraintes sur la surface des objets.
- Enfin, le caractère séquentiel ou progressif de la procédure permet de s'appuyer sur la segmentation de certains objets pour aller vers des objets de plus en plus difficiles à segmenter.

# 198 Quatrième partie

Cette procédure est ensuite détaillée : nous expliquons comment nous gérons l'évolution d'un champ de correspondance entre l'image et l'atlas (chapitre 11), comment nous réalisons la classification, la fusion et la segmentation (chapitre 12), et enfin, comment nous mettons en œuvre l'ensemble de la procédure de reconnaissance (chapitre 13). Ce dernier présente également les premiers résultats obtenus.

# **Chapitre 9**

# État de l'art sur les méthodes de reconnaissance à base d'atlas anatomiques

Depuis quelques années, l'utilisation d'atlas anatomiques s'est imposée comme une aide à la reconnaissance des structures cérébrales, et de nombreux travaux actuels concernent l'élaboration d'atlas « standardisés ». De tels atlas ne représentent pas seulement un système de repérage invariant ; ils offrent aussi la possibilité de superposer à l'image du cerveau du patient des modèles anatomiques, qui peuvent alors permettre l'identification des structures cérébrales du patient, ainsi que leur analyse.

Un véritable enjeu scientifique et médical réside dans la reconnaissance automatique en IRM anatomique d'une part importante des structures cérébrales. Les atlas ne serviraient plus de références anatomiques absolues aux études neurofonctionnelles, mais ils seraient, lors de l'examen d'un patient, directement remplacés par la cartographie anatomique cérébrale du patient lui-même, cartographie individuelle accessible grâce à la segmentation d'images par résonance magnétique du cerveau.

Dans ce chapitre, nous proposons une synthèse des méthodes de reconnaissance par déformation d'atlas. Nous présentons tout d'abord les atlas principaux utilisés (section 9.1). Puis nous donnons une classification des modèles de déformation, selon le type de primitives sur lesquels ils s'appuient : points, lignes, surfaces, volumes (section 9.2).

# 9.1 Les atlas existants

Les articles de recherche qui traitent de la segmentation des structures internes du cerveau à l'aide d'atlas anatomiques informatisés, et qui ont paru ces dernières années, sont en nombre croissant. Cette évolution va de pair avec l'avènement de l'ère numérique; ainsi les références anatomiques sous forme d'atlas ont évolué des livres vers des représentations numériques, dont plusieurs sont disponibles sur *Internet*.

# 9.1.1 Du papier au tout numérique

Les premiers atlas du cerveau étaient des atlas sur papier où les structures cérébrales étaient dessinées manuellement. Depuis le tout premier atlas dressé par André Vésale au XVI<sup>e</sup> siècle, les progrès de la médecine ont progressivement augmenté la masse de connaissances concernant l'organe cerveau.

Les atlas sur papier traduisent ces progrès et les informations portées sur les schémas sont de plus en plus nombreuses et précises. Elles peuvent être de natures différentes : régions, lignes ou points caractéristiques, mais sont toutes mélangées dans les planches des atlas. La présentation de ces informations nécessite, en l'absence d'une troisième dimension, de multiplier le nombre de coupes descriptives dans l'atlas.

Avec l'utilisation en routine clinique de techniques non invasives telles que l'imagerie par résonance magnétique, les atlas ont incorporé des vues numériques du cerveau (par exemple l'atlas français [DUVE-92]); le futur praticien peut ainsi se familiariser avec ces images qui deviendront un véritable outil de travail. La résolution de telles images restant faible, au mieux légèrement inférieure au millimètre, et leur contraste ne permettant pas de distinguer l'ensemble des structures cérébrales, les planches anatomiques dessinées demeurent un complément encore indispensable à ces atlas.

Citons quelques atlas sur papier dédiés à l'anatomie : [LUDW-56] [WRIG-59] [FENE-67] [MATZ-67] [ROBE-70] [FORD-71] [WOLF-72] [DUNK-75] [DEAR-76] [INGR-76] [TRUE-76] [TALM-77] [WATS-77] [ZULE-77] [MATS-78] [BARR-79] [HANA-80] [CLEM-85] [KRET-86] [CARP-91] [MART-96], et quelques uns dédiés plus particulièrement à l'anatomie fonctionnelle : [SINE-63] [EVER-71] [WILL-75] [ROHE-75] [HEIM-95] [NOBA-96]. Cette liste témoigne de l'importance croissante des travaux dans le domaine neurologique.

Les vues présentées dans les atlas sur papier sont le plus souvent axiales et malheureusement, même avec un nombre de coupes important, la compréhension tridimensionnelle de la morphologie et de l'agencement des structures anatomiques complexes est délicate. Aussi, de plus en plus d'atlas proposent quelques coupes supplémentaires, sagittales et/ou coronales, et quelques vues tridimensionnelles. La difficulté de compréhension, bien que réduite, reste présente et le suivi d'une structure anatomique d'une planche à l'autre n'est pas une tâche facile.

Les atlas sur papier ont d'autres inconvénients: pour ne pas surcharger les planches, l'exhaustivité des informations est limitée et les informations descriptives sont rares; enfin, la variabilité anatomique n'est pas prise en compte. Les atlas numériques offrent des solutions à ces problèmes.

Avec les atlas numériques, la visualisation des informations peut être réalisée par exemple grâce à trois vues simultanées de la même acquisition (voir figure 9.1): une axiale, une sagittale et une coronale. L'utilisateur a alors la possibilité de se déplacer coupe par coupe dans chaque vue indépendamment des autres ou, pour un point d'une vue donnée, d'aller à la coupe correspondante des deux autres vues. A tout moment, l'utilisateur a accès aux informations de l'atlas.

Ces représentations sont informatiques et leur principale limitation est la faiblesse relative de la résolution des atlas numériques. En revanche, cette résolution est pleinement exploitée, le nombre de vues étant très supérieur à celui d'un atlas sur papier et, la navigation dans le volume de données étant intuitive, la compréhension de l'atlas est facilitée. Des vues tridimensionnelles peuvent compléter le tout. Le logiciel *Voxel-Man*<sup>1</sup> est prévu à cet effet ; il est développé par l'équipe d'imagerie médicale de l'Université de Hambourg (Allemagne) : Höhne [HOHN-92a], Tiede [TIED-93], Bomans [BOMA-90] *et al.* Les logiciels de ce type peuvent être plus que de simples outils de visualisation ; ainsi *Voxel-Man* est devenu une plateforme de segmentation en 3D [HOHN-92b] (figure 9.2), et a servi à l'élaboration d'un atlas.

<sup>1.</sup> http://www.uke.uni-hamburg.de/Institutes/IMDM/IDV/IDV\_HomePage.html



FIG. 9.1 – Navigateur dans les coupes d'IRM

Ce logiciel, que nous avons écrit alors qu'il n'existait pas d'outils similaires en domaine public, permet non seulement de se déplacer dans les vues axiale, coronale et sagittale (pour mieux apprécier en 3D l'anatomie cérébrale), mais aussi de créer des masques binaires (pour l'apprentissage des statistiques radiométriques par exemple, ou pour la correction d'une segmentation), ou de visualiser simultanément différents masques (pour la création d'un atlas par exemple).

La quantité d'informations portées par l'atlas peut être importante et de nature diverse sans pour cela nuire à la représentation. Néanmoins le détail de la forme des structures est limité par la résolution.

# 9.1.2 Atlas et normalisation

Un atlas du cerveau se caractérise tout d'abord par les informations qu'il contient. Ces informations consistent généralement en une description de la morphologie des structures, et en un repérage spatial. De ce dernier émerge la notion de normalisation de l'espace cérébral.

## L'atlas-repère de Talairach

En 1967 paraît l'atlas de Talairach et Tournoux [TALA-67] (puis [TALA-88] et [TALA-93]); son but est de normaliser les données du cerveau grâce à un repère intrinsèque au cerveau. C'est la première approche stéréotaxique de l'étude du cerveau.

Le repère de Talairach est un repère anatomique  $(O \Leftrightarrow XYZ)$  s'appuyant sur des caractéristiques cérébrales précises :

- l'origine O du repère est l'intersection entre la commissure antérieure (AC) et le plan interhémisphérique,
- l'axe des X est perpendiculaire au plan inter-hémisphérique,
- l'axe des Y (ligne AC-PC) passe par l'aspect inférieur de la commissure postérieure (PC),
- l'axe des Z est orthogonal aux deux autres axes,
- les coordonnées sur les axes de ce repère sont normalisées en considération de la plus petite boîte qui englobe le cortex et dont les côtés sont parallèles aux plans liés au repère.



FIG. 9.2 – Plateforme de segmentation tridimensionnelle



L'espace limité par la boîte englobante est subdivisé en 12 sous-volumes grâce aux trois discriminants : à gauche ou à droite par rapport au plan inter-hémisphérique  $(O \Leftrightarrow YZ)$ , supérieur ou inférieur au plan  $(O \Leftrightarrow XY)$  appelé aussi plan AC-PC, antérieur au plan  $(AC \Leftrightarrow XZ)$  ou postérieur au plan  $(PC \Leftrightarrow XZ)$  ou entre les deux.

Afin de prendre en compte la variabilité morphologique du cerveau humain qui ne s'exprime pas de façon linéaire, l'immersion d'une image cérébrale dans l'espace de normalisation de Talairach doit respecter le partage de l'image en sous-volumes; la déformation préconisée par Talairach est donc multi-linéaire par morceaux.

Dans [TAKA-77], il est montré que les plans  $(O \Leftrightarrow XY)$ ,  $(AC \Leftrightarrow XZ)$  et  $(PC \Leftrightarrow XZ)$  fournissent une référence anatomique plus précise que d'autres plans caractéristiques du cerveau, ce qui confirme l'intérêt de ce repérage, et explique que l'espace de Talairach constitue aujourd'hui un référentiel classique de normalisation pour la recherche en neurologie.

Nous n'avons trouvé qu'une seule référence [SEND-94] d'étude critique des méthodes de normalisation dans l'espace de Talairach; sa conclusion a cependant des conséquences importantes: les différentes méthodes de normalisation mènent en pratique à des résultats notablement différents pour la localisation de zones d'activation. Cependant, malgré l'erreur de normalisation, et malgré la variabilité existant entre le sujet et la référence, la qualité des résultats reste très correcte pour les structures cérébrales sous-corticales.

Cette observation a posteriori conduit à plusieurs conclusions, en ce qui concerne la région sous-

corticale:

- le repère de Talairach est bien adapté à la normalisation d'images cérébrales,
- son utilisation dans les applications énumérées en section 9.1.2 est donc justifiée,
- la variabilité inter-individu paraît faible lorsqu'une normalisation même globale est réalisée,
- le choix d'une normalisation n'a pas d'influence sur le niveau de qualité du résultat.

En conclusion, une normalisation (donc en particulier celle de Talairach) donne une bonne initialisation pour l'obtention ultérieure d'une segmentation précise de l'image cérébrale d'un sujet.

#### Normalisation, atlas, et applications

Nous pouvons distinguer trois groupes principaux d'applications de la normalisation.

Le premier est l'obtention d'une référence anatomique.

Pour des études fonctionnelles [SCHI-94a] par exemple, que le type d'imagerie employé soit de la tomographie par émission de positrons (*PET*) ou de la résonance magnétique fonctionnelle (*IRMf*), l'image fonctionnelle étudiée est tout d'abord ramenée dans l'espace normalisateur; une zone d'activation dans l'image est alors repérée dans l'atlas, et la région anatomique concernée est ainsi déterminée.

Pour des études anatomiques, le procédé est le même, et l'atlas indique dans l'image anatomique la localisation approximative des différentes structures. Cette localisation peut alors servir d'initialisation à des procédures de reconnaissance précise des structures de l'image.

Un second groupe d'applications est la comparaison de cerveaux.

Il s'agit par exemple de suivre l'évolution d'une pathologie chez un sujet [NELS-94], de distinguer des cerveaux de malades mentaux de ceux de personnes saines [BOOK-96] ou, d'évaluer la variabilité anatomique cérébrale [TOGA-93] [EVAN-96]. Dans tous les cas, les images du cerveau sont inscrites dans l'espace normalisateur afin de les comparer finement.

Le troisième groupe d'applications est de servir de référentiel spatial pour la construction d'atlas « probabilistes » du cerveau.

De tels atlas sont des volumes qui contiennent en chaque voxel la probabilité de présence d'un certain nombre de structures. Ils sont constitués à partir d'un ensemble d'images, segmentées puis placées dans un référentiel commun (par exemple l'espace de Talairach). La probabilité d'un tissu en chaque voxel se déduit alors par un simple comptage dans l'ensemble des images segmentées [LIM-89] [OTAK-95]. Pour que le substantif « probabiliste » ne soit pas un abus de langage, un nombre important d'images doivent être prises en compte, ce qui rend pénible l'étape de segmentation.

De façon similaire, des représentations moyennes de l'anatomie cérébrale en IRM sont construites; ce ne sont plus des probabilités qui sont exprimées, mais seulement une radiométrie moyenne en chaque voxel. Les images, une fois placées dans un référentiel, sont d'abord requantifiées avant d'être tout simplement moyennées [ANDR-94a] [EVAN-96]. Le résultat est une image floue, en raison de la variabilité inter-individus. Notons que pour ce type d'application, des bases de données d'images cérébrales ont été constituées dans le repère de Talairach [FOX-94a].

## Où l'on reparle de numérique

Dans les atlas numériques, le repérage spatial et les descriptions morphologiques des différents objets sont donnés implicitement par la structure de données utilisée. L'atlas est généralement représenté sous la forme d'une image volumique où chaque voxel est porteur d'informations.

Dans le cas d'atlas probabilistes, ces informations sont stockées dans un vecteur, dont les coordonnées traduisent les probabilités d'appartenance de ce voxel à différentes structures. Dans le cas d'atlas d'étiquettes, ces informations se réduisent à une simple étiquette, caractéristique de la structure cérébrale à laquelle appartient ce voxel. Chaque voxel étant un élément de la matrice-image, il est clairement localisé, et le repérage spatial est défini par la topologie de l'image.

Si la résolution intra-coupe axiale de la version informatisée de l'atlas de Talairach que nous possédons (au département Images) est élevée (768 points par 908, Cf. figure 9.3), son nombre de coupes est limitée à 27, à l'instar de la version papier. Cette limitation, ajoutée à celle de la trop schématique morphologie des structures anatomiques qu'il décrit, fait qu'il ne peut être employé tel quel comme un atlas anatomique volumique.



FIG. 9.3 – Coupe axiale d'un atlas numérique de Talairach

Cette coupe est extraite d'un atlas numérique de Talairach et Tournoux [TALA-93]; les formes des structures y sont volontairement schématiques.

Pour s'affranchir de ces limitations, des atlas numériques ont été construits de toutes pièces, en s'efforçant toujours de représenter une anatomie « moyenne » du cerveau. Dans [EVAN-88] par exemple, un atlas numérique a été construit pour des études neurofonctionnelles, en s'appuyant sur l'atlas de Talairach et sur trois atlas existants dédiés à l'aspect fonctionnel ([HANA-80][KRET-86][MATS-78]); 56 structures distinctes sont identifiées dans cet atlas. Le projet américain « *Visible Human Project* »<sup>1</sup> [ACKE-91][SLAV-97], initié en 1986 par la *National Library of Medicine (National Institute of Health)*, a pour but de proposer une référence exhaustive, issue de sujets humains (pour l'instant un homme et une femme), pour l'ensemble des travaux de recherche en anatomie. En particulier, des acquisitions IRM et CT couvrant une partie du corps, dont la tête, ont été également mises en œuvre. Ce n'est donc pas à proprement parler un projet de construction d'atlas, et *a fortiori* d'atlas du cerveau ; néanmoins, nous avons noté l'apparition récente d'atlas du cerveau bâtis à partir de cette nouvelle référence [TOH-96].

A noter, le Laboratoire d'Interaction Homme-Machine du Département Informatique de l'Université de Maryland (College Park, U.S.A.) met à notre disposition, en domaine public sur *Internet*<sup>2</sup>, un logiciel très complet de visualisation des données du *Visible Human Project* [NORT-98].

# 9.1.3 Le numérique sur le web

Avec *Internet* et ses outils dérivés sont apparus des atlas entièrement numériques, consultables à distance. Les prérequis sont que l'utilisateur soit connecté à *Internet*, et quelquefois qu'il dispose d'une machine virtuelle *java*<sup>3</sup>. Une contrainte inhérente au réseau est son faible débit [DAIL-96]; les atlas qui s'y trouvent sont donc souvent soit limités en nombre de coupes et d'informations, soit réservés à un usage local.

- *The Digital Anatomist Project* Le Département de Biologie Structurelle de l'Université de Washington (Seattle, Washington, U.S.A.) nous propose<sup>4</sup> de nombreuses images bidimensionnelles, vues tridimensionnelles et animations associées, le tout réparti en plusieurs catégories (figure 9.4), ainsi que des questionnaires sur l'anatomie. L'interactivité de ce site s'appuie sur des *C.G.I.*<sup>5</sup>; cette mise en œuvre revient à Sundsten *et al.* [BRIN-93][BRAD-95]. Les figures utilisées dans le chapitre 1 de la partie I de ce manuscrit proviennent d'images de ce site, retravaillées pour l'occasion.
- *The Whole Brain Atlas* Johnson et Becker [JOHN-93] de l'Ecole de Médecine de l'Université d'Harvard (Boston, U.S.A.) propose un navigateur<sup>6</sup> développé en *java* pour se déplacer dans des vues axiales issues de différents types d'acquisitions, anatomiques et fonctionnelles (figure 9.5), ou de reconnaître interactivement des structures cérébrales.
- *BrainWeb* Au Centre d'Imagerie Cérébrale McConnell Brain Imaging Centre de l'Institut Neurologique de Montréal (McGill University, Canada) a été développé un simulateur d'images par résonance magnétique<sup>7</sup> sous l'autorité d'Evans [KWAN-96][COCO-97]. L'image visualisée dépend des paramètres de l'acquisition et est construite à partir d'une image modèle (figure 9.6).
- *CleMed* La Division de Neuroradiologie de l'Ecole de Médecine de l'Université Johns Hopkins (Wahington DC, U.S.A.) en collaboration avec l'Université Nationale de Singapour propose en ligne<sup>8</sup> plusieurs atlas. C'est le cas en particulier de celui de Talairach [TALA-93], intégré

<sup>1.</sup> http://www.nlm.nih.gov/research/visible/visible\_human.html

<sup>2.</sup> http://www.cs.umd.edu/projects/hcil/Research/1995/vhe.html

<sup>3.</sup> interpréteur du langage multi-plateformes *java* de *Sun Microsystems* (http://www.javasoft.com/); gratuit, il est utilisé en module externe par les navigateurs de *Netscape* (http://home.netscape.com/) ou de *Microsoft* (http://www.microsoft.com/)

<sup>4.</sup> http://wwwl.biostr.washington.edu/DigitalAnatomist.html

<sup>5.</sup> Common Gateway Interfaces

<sup>6.</sup> http://www.med.harvard.edu/AANLIB/home.html

<sup>7.</sup> http://www.bic.mni.mcgill.ca/brainweb/

<sup>8.</sup> http://ditzel.rad.jhu.edu/IIA/



FIG. 9.4 - Sommaire du Digital Anatomist Project

A partir de ce sommaire (http://www9.biostr.washington.edu/ cgi-bin/DA/imageform), on peut choisir le type d'atlas que l'on souhaite examiner; de nombreuses visualisations sont alors disponibles ainsi que l'identification des structures cérébrales [BRIN-93][BRAD-95].

à une appliquette *java* illustrée en figure 9.7 ; malheureusement le nombre de vues par plan de coupe est limité à une vingtaine.

- The SPL Anatomy Browser Le logiciel du Laboratoire de Planning Chirurgical (d'acronyme anglais  $SPL^1$ ), commun à l'Ecole de Médecine de l'Université d'Harvard (Boston, U.S.A.) et à l'Hôpital de Brigham & Women (Boston, U.S.A.), est dû à Shenton [SHEN-95], Kikinis [KIKI-96] et al. Ecrit en java, il peut être récupéré sur simple demande ; une version réduite est disponible sur Internet<sup>2</sup>. De loin le logiciel gratuit le plus abouti que l'on puisse trouver, il propose une vue tridimensionnelle en complément des vues dans chaque plan de coupe, et une présentation des structures cérébrales sous forme de menu hiérarchique (Cf. figure 9.8); le degré d'interactivité est élevé, le déplacement dans le volume se réalise en cliquant dans les vues des plans de coupe et un clic sur une structure représentée en 3D fait apparaître son nom. L'atlas utilisé a été segmenté à partir d'une acquisition en  $T_1$  de plan de coupe coronal.
- *The Human Brain Project* L'initiative la plus originale est sans doute celle du Groupe de Traitement de Signaux Neuronaux de l'Université Technique du Danemark<sup>3</sup> [NIEL-98]. La morphologie des structures cérébrales a été modélisée à l'aide de V.R.M.L. (*Virtual Reality Modeling Language*), norme textuelle destinée à *Internet* de description de mondes virtuels<sup>4</sup>. Différentes

<sup>1.</sup> http://splweb.bwh.harvard.edu:8000/pages/index.html

<sup>2.</sup> http://splweb.bwh.harvard.edu:8000/pages/papers/smalljava/BB.small.html

<sup>3.</sup> http://hendrix.imm.dtu.dk/

<sup>4.</sup> un fichier décrivant une scène 3D et pointé par une page H.T.M.L. est pris en charge par un module externe au navigateur afin de fournir une représentation 3D du monde et de gérer les déplacements et les actions de l'utilisateur dans


FIG. 9.5 – Panneau extrait du Whole Brain Atlas

L'interface permet de choisir parmi les cinq types d'acquisition proposés les trois qui seront visualisées, de choisir aussi leur date afin de suivre l'évolution de pathologies dans le temps, et de se déplacer d'une coupe axiale à une autre [JOHN-93].



FIG. 9.6 – Pages extraites du BrainWeb

Afin de simuler une IRM 3D cérébrale, l'internaute peut sélectionner, à partir d'une première page (en haut dans cette figure), le type de modalité, l'épaisseur des coupes, la quantité de bruit et l'intensité de l'hétérogénéité du champ ; une seconde page présente la simulation sous forme de vues des trois plans de coupe qui permettent à l'internaute de balayer le volume [KWAN-96][COCO-97].

scènes sont proposées : des « blobs » d'activation représentés dans le repère de Talairach, la convergence d'un modèle s'appuyant sur le gradient de l'image et ayant pour but de segmenter la surface du cerveau, une galerie de musée sur le thème des images du cerveau, etc.

ce monde (plus de renseignements sur V.R.M.L. sont disponibles à partir de la page officielle http://www.vrml.org/ ou du dépôt http://sdsc.edu/vrml/)



FIG. 9.7 – Atlas de Talairach de CIeMed

Cliquer dans une image de l'atlas de Talairach [TALA-93] fait apparaître le nom de la structure cérébrale ; les images, dans chaque plan de coupe, peuvent être sélectionnées grâce aux ascenseurs.

# 9.2 Modèles de déformation

Nous présentons ici différents modèles de déformation qui permettent de mettre en correspondance une image avec une référence (un atlas ou une seconde image); nous avons choisi de les classer en fonction du type de primitives qui induit la déformation. Pour notre problème de segmentation des structures cérébrales, la finalité des déformations est, explicitement ou implicitement, une reconnaissance de ces structures.

# 9.2.1 Primitives points, droites, plans

# Normalisation de Talairach

L'utilisation conjointe de l'espace de Talairach et d'un atlas, normalisé dans cet espace, peut être un outil de segmentation [SCHI-94a] [EVAN-96]. En effet, l'atlas fournit des informations anatomiques et fonctionnelles, et celles-ci sont accessibles si la transformation qui permet de passer de



FIG. 9.8 – The SPL Anatomy Browser



l'espace de l'image à celui de Talairach est déterminée.

Ce passage nécessite tout d'abord la localisation des lignes et plans caractéristiques (décrits en section 9.1.2); cette localisation est quelquefois automatisée [FOX-85] [FRIS-89] [VERA-97] mais le plus souvent semi-automatisée [LANC-95].

Si les primitives utilisées pour la normalisation sont des lignes et des plans, dont la localisation dans l'image donne souvent lieu au repérage d'un ensemble de points caractéristiques, notons que l'intégralité du volume des voxels est généralement prise en compte pour l'obtention du plan interhémisphérique en IRM [ALLA-92] [WOOD-93a] [COLL-94]; les techniques employées relèvent de la corrélation entre les deux hémisphères.

A quelques exceptions près [LEMO-91] [THOM-96a] [ROYA-97], la déformation multi-linéaire par morceaux de Talairach n'est ensuite pas respectée. Une simplification consiste alors à ne considérer qu'une déformation globale et multi-linéaire [COLL-94] [EVAN-96] [DESM-97].

A l'inverse, d'autres approches donnent lieu à des déformations non-linéaires. Dans [WOOD-93b], les axes des facteurs d'échelles ne sont pas obligatoirement orthogonaux ; dans [GREI-91] et [THUR-93], la normalisation est interactive, et incorpore des déformations quadratiques.

### Points d'amer (ou points homologues)

Dans [EVAN-96], un ensemble de points d'amer sont utilisés pour obtenir le plan AC-PC à l'aide d'une régression linéaire ; en étendant cette idée, une mise en correspondance globale du volume de

deux images, ou d'une image et d'un atlas, peut s'appuyer sur une liste de points d'amer dont la définition est fixée.

La liste de ceux-ci est définie dans l'atlas et les points homologues sont identifiés par un clinicien dans l'image de la tête du patient. La transformation qui permet de passer d'un ensemble de points à l'autre est alors étendue à l'intégralité du volume.

Dans [BOOK-96], une étude de la variabilité anatomique du cerveau entre deux groupes de personnes, schizophrènes et non-schizophrènes, est menée en IRM. Dix points anatomiques du plan inter-hémisphérique ont été retenus ; la mise en correspondance des jeux d'amers d'un même groupe est effectuée en minimisant la distance de Procrustes [KEND-84]. Enfin, la déformation induite par le passage des amers-moyens du groupe non-schizophrénique à ceux du groupe schizophrénique est obtenue par des flexions par splines de plaques minces (*thin-plate spline*) [BOOK-89]. Dans cet article, la déformation se limite au plan inter-hémisphérique, mais cette procédure peut être facilement étendue à des données tridimensionnelles.

De telles approches présentent plusieurs inconvénients. La transformation induite par la mise en correspondance des points peut beaucoup varier avec le nombre de points choisis et leur localisation [BOOK-91]. De plus, l'erreur subjective lors de l'identification des points peut être importante, car elle requiert une véritable expertise.

Citons une application très représentative des précautions à prendre avec ce type de méthodes. Dans [COLL-94], la mesure comparative de la performance entre algorithmes de recalage est réalisée; le recalage de référence est donné par une procédure utilisant des points d'amer, identifiés manuellement dans l'image à recaler et dans les images recalées. Pas moins de 51 points d'amer sont utilisés afin de garantir la justesse de la mesure comparative; leur répartition caractérise des structures longitudinales antéro-postérieures, des structures inter-hémisphériques, des régions corticales et la morphologie cérébrale externe.

# 9.2.2 Primitives linéiques

Des modèles plus structurés qu'un simple ensemble de points peuvent conduire à des déformations plus précises. C'est le cas de correspondances qui s'appuient sur des lignes mettant en exergue l'anatomie du cerveau. Elles sont de diverses natures, et les algorithmes qui les extraient sont spécifiques. Leur application en imagerie cérébrale est généralement limitée à la surface du cerveau et, plus particulièrement, à l'extraction des sillons.

# Lignes de crêtes

Les lignes de crêtes [MONG-92] d'une surface représentent les endroits les plus courbés de cette surface.

Dans [SUBS-95], deux applications de mise en correspondance entre deux images par résonance magnétique, dont une de référence, sont présentées. Les lignes de crêtes sont calculées (par une adaptation [THIR-93] de l'algorithme des *Marching Cubes*) sur la surface externe du cortex pour la première application, et sur le système ventriculaire pour la seconde ; elles suivent donc respectivement les circonvolutions corticales, et les bords anguleux des structures ventriculaires. Pour chaque application, la correspondance entre les deux ensembles de lignes est obtenue par une heuristique itérative, et grâce à une extension [FELD-96] non-rigide de l'algorithme ICP [BESL-92] (voir en sections 9.2.3 et 9.2.4). La transformation qui permet de passer de l'image de référence à la seconde image est, dans les deux cas, extrapolée dans les trois dimensions par des fonctions B-splines cubiques.

Les résultats montrent seulement la surface externe du cortex et des ventricules de l'image de référence, superposés à la seconde image après transformation. Si la mise en correspondance de ces structures est bonne, nous ne pouvons pas juger de la pertinence de la transformation sur l'intégralité du volume.

### Autres types de lignes

D'autres types de lignes caractéristiques existent; leur utilisation pour un calcul de correspondance peut être similaire à celui de l'exemple précédent. Méanmoins, aucun autre type de lignes ne paraît mieux adapté pour caractériser la morphologie d'une structure.

Les lignes géodésiques, par exemple, sont les lignes les plus courtes qui relient deux points sur une surface. Pour qu'elles traduisent des caractéristiques pertinentes, la morphologie des surfaces qui les portent doit être très particulière; en effet, si une petite variation de la surface peut induire un changement radical des lignes géodésiques correspondantes alors leur utilisation risque d'être compromise [CUTT-93].

# 9.2.3 Primitives surfaciques

Afin de mettre en correspondance deux images ou une image et un atlas, nous pouvons avoir recours à des informations plus structurées que ne le sont les points d'amer ou les lignes : des surfaces. Comme précédemment, l'identification de surfaces dans les images de cerveau peut conduire à l'obtention d'une déformation et, par voie de conséquence, d'une segmentation avec reconnaissance.

De nombreuses techniques de recalage [VANE-93], aujourd'hui classiques, apportent des solutions au problème de mise en correspondance de surfaces. En particulier, le recalage de surfaces cérébrales a fait l'objet de nombreux travaux de recherche. Les études neuro-fonctionnelles, qui sont menées sur un patient dont le cerveau est acquis, d'une part par tomographie par émission de positrons (*PET*), et d'autre part par imagerie anatomique par résonance magnétique, nécessitent la mise en correspondance de ces images; or en imagerie PET, la surface du cerveau est observable, et la mise en correspondance s'appuie donc généralement sur le recalage au préalable des surfaces du cerveau de ces deux images.

Si la surface du cerveau est définie dans l'atlas, la mise en correspondance d'un atlas et d'une image s'inscrit intuitivement dans cette même problématique.

### Approches par recalage rigide

Une première approche est la *méthode d'égalisation des moments* [FABE-88]. Chaque surface (celle à recaler et celle de référence) délimite un volume pour lequel son centre de masse et sa matrice d'inertie d'ordre deux sont calculés. La transformation qui permet de passer d'une surface à l'autre se déduit de ces informations : une translation met en correspondance les centres, une rotation fait se superposer les axes d'inerties (vecteurs propres des matrices, ordonnés par leurs valeurs propres), et des facteurs d'échelle le long de ces axes sont définis par la racine carrée du rapport de leurs valeurs propres associées.

Une restriction majeure de la méthode d'égalisation des moments, pour qu'elle soit pertinente, est que les volumes à faire correspondre doivent avoir des axes d'inertie bien distinguables, donc des formes très particulières. Cette méthode ne pouvant pas être employée pour l'ensemble des nombreuses structures cérébrales, on lui préfère d'autres approches, soit spécificiques à une structure donnée, soit au contraire générales, mais plus adaptées à la morphologie des objets cérébraux. Dans [BAJC-89], la méthode d'égalisation des moments est utilisée comme initialisation d'un recalage élastique.

Une méthode, qui a connu un franc succès pour le recalage du cerveau est due à *Pelizarri* [PELI-89]. Elle définit la distance entre un point de la surface à recaler (une fois re-discrétisée) et la surface du cerveau de référence, par la distance euclidienne entre ce point et l'intersection de la ligne qu'il forme avec le centre de masse de l'objet de référence. Le recalage s'effectue alors en recherchant (à l'aide de l'algorithme de la direction de Powell [POWE-64] ou de celui de la matrice variable [PRES-88]) la transformation rigide qui minimise l'erreur quadratique moyenne, au sens de cette distance, entre les deux surfaces.

Du fait de la distance utilisée, cette méthode est bien adaptée au recalage de formes plutôt ovoïdes qui ne présentent pas d'irrégularités importantes. Si elle est donc valable pour la surface du cerveau, elle n'est pas adaptée aux structures cérébrales de formes oblongues, comme celles des ventricules ou de certains noyaux.

L'algorithme itéré du point le plus proche de Besl et McKay [BESL-92] suit le même principe que celui de Pelizzari, mais utilise une distance plus intuitive, la distance au plus proche point de la surface de référence, et s'applique à des objets de formes et de représentations (nuage de points, triangulation, etc.) quelconques.

En notant X la surface de référence, et  $P_0$  la discrétisation de la surface à recaler, l'algorithme peut se décrire ainsi :

- 1. k = 0
- 2. calculer l'ensemble  $Y_k$  de points tel que le  $i^{\text{ème}}$  point de  $Y_k$  est le point de X le plus proche du  $i^{\text{ème}}$  point de  $P_k$ ;
- 3. calculer la transformation rigide  $R_k$  qui minise l'erreur quadratique moyenne  $e_k = ||Y_k, \Leftrightarrow R_k(P_0)||^2$ ;
- 4. calculer  $P_{k+1} = R_k(P_0)$
- 5. si  $e_k$  est suffisamment faible, arrêter l'algorithme; sinon faire k = k + 1 et retourner en 2.

Dans [FELD-96], cet algorithme a été étendu pour prendre en compte non seulement des transformations élastiques, mais aussi l'ensemble des informations d'intensité des images (en IRM, de radiométrie). Cette extension relève donc d'une approche volumique; elle est décrite en section 9.2.4.

L'inconvénient majeur de ces algorithmes, dans le cadre de la mise en correspondance de structures cérébrales avec leurs représentations dans un atlas, est leur limitation aux transformations rigides; la correspondance obtenue est grossière, mais peut servir d'initialisation pour des raffinements ultérieurs.

# Approches par modèles déformables

Afin d'introduire une certaine souplesse dans la mise en correspondance, des approches se fondent sur des modèles déformables [MCIN-96]. Ces derniers résultent de la confluence de trois disciplines :

- la géométrie, pour décrire la forme et la taille de l'objet à segmenter,
- la physique, pour contraindre les variations du modèle,
- et la théorie des approximations, pour mettre en conformité le modèle avec les données dans lesquelles se trouve l'objet recherché.

Pratiquement, la déformation géométrique autorise beaucoup de degré de liberté, mais est conditionnée par deux facteurs énergétiques : les contraintes physiques, forces internes au modèle qui maintiennent sa continuité et sa régularité, et l'attache aux données, forces externes qui attirent le modèle vers l'objet. L'équilibre énergétique fait donc l'objet d'une optimisation, au cours de laquelle le modèle se positionne dans l'image en se déformant.

Utilisés tout d'abord dans les images bidimensionnelles [KASS-88], les modèles déformables (ou *snakes*) ont été naturellement étendus au 3D [TERZ-88]. Les surfaces déformables revêtent plusieurs formes (les modèles volumiques déformables seront traités dans la section 9.2.4 suivante).

Dans [THOM-96b], *Thompson et Toga* utilisent deux surfaces : la surface extérieure du cortex et la surface du système ventriculaire. Chaque surface, définie dans l'atlas, est extraite de l'image à traiter par un modèle de surface active dû à Cohen et Cohen [COHE-91] [COHE-92a] [COHE-92c]. Dans ce modèle, la géométrie est celle d'une sphère (ou ballon), et sa structure s'appuie sur les méthodes d'éléments finis ; un terme énergétique de gonflement [COHE-93] permet d'éviter le positionnement final erroné du ballon sur des surfaces indésirables de l'image.

Comme pour tout modèle déformable, l'initialisation de la position du modèle dans l'image à traiter est très importante. Elle est réalisée, dans cette application, par une surface de Chen [CHEN-94b], positionnée dans l'image pour s'adapter au mieux à des points d'amer ; ceux-là sont repérés manuellement dans l'image, et appartiennent à la surface recherchée (soit la surface externe du cortex, soit celle du système ventriculaire).

Les surfaces externes du cortex et du système ventriculaire font respectivement l'objet de deux et quatre maillages par hémisphère. Après l'obtention de ces surfaces dans l'image à traiter, la déformation qui permet de passer de l'atlas à l'image est connue sur ces surfaces. L'extension de la déformation à l'ensemble du volume est alors réalisée.

Une méthode simple considère qu'un point du volume a pour déplacement, la moyenne des déplacements de ses plus proches voisins  $np_i$  sur chaque maillage, pondérée par les distances entre ce point et ses plus proches voisins [RUPR-95]. Dans [THOM-96b], une variante de cette méthode est proposée, et tient compte pour chaque maillage  $M_i$ , non plus du seul déplacement en  $np_i$ , mais des déplacements du voisinage sur  $M_i$  de  $np_i$ , via une pondération par une gaussienne centrée en  $np_i$ .

Les résultats de la mise en correspondance, montrés pour deux exemples sur une coupe sagittale médiale, sont probants. Une des idées intéressantes de cette approche est d'inférer la déformation volumique à partir de deux surfaces : la surface externe du cortex, qui imprime la forme du cerveau, et la surface du système ventriculaire, qui organise les structures centrales. Cette idée n'est pas nouvelle, elle a été mise en œuvre par *Bajcsy et al.* [BAJC-83] pour superposer un atlas à des images tomographiques, puis évaluée dans [GEE-93].

Dans [SAND-94a], *Sandor et Leahy* utilisent un modèle élastique de surface avec des B-splines 3D bicubiques pour la mise en correspondance d'un atlas du cortex avec des images par résonance magnétique. La surface cible est la surface externe du cortex avec ses dépressions dues aux sillons. Afin de faciliter la convergence de la localisation du modèle vers cette surface, les images à traiter sont pré-traitées : à l'aide d'un détecteur de contour [MARR-80] et d'opérateurs morphologiques, la surface du cerveau et les sillons sont détectés, et l'image lissée.

Dans [SZEL-93], *Szeliski et Lavallée* utilisent la conjugaison de transformations rigide, affine, puis locale (par un produit tensoriel de B-splines), afin de mettent en correspondance deux surfaces décrites par des nuages de points. Le calcul de la dernière transformation est effectuée de façon hiérarchique (avec pour cela, un partitionnement par *octree* de l'espace).

Notons que la transformation obtenue par cette méthode est directement globale à l'espace des données (donc au volume des images), contrairement aux approches précédentes élastiques, où elle

doit être extrapolée à partir de la déformation connue surfaciquement.

# 9.2.4 Primitives volumiques

Enfin, un dernier type d'approche consiste à mettre en correspondance directement l'ensemble des voxels d'une image avec celui d'une seconde image. Ce type d'approche a donc pour primitive les volumes; il ne s'appuie pas sur une structuration des formes, comme c'est le cas des approches décrites dans les sections précédentes.

### Approches par modèles déformables

Deux modèles déformables différents ont été empruntés à la physique : celui des solides élastiques et celui des fluides visqueux.

Le modèle des solides élastiques apparaît dans la thèse de *Broit* [BROI-81], à qui nous devons l'idée de déformer un atlas vers des données. Par la suite, une version multi-résolutions a été mise en œuvre par *Bajcsy et Kovacic* [BAJC-89].

La fonction de déplacement u(p) qui indique, pour un voxel p d'un atlas A, son correspondant p + u(p) dans l'image I, est recherchée. Pour cela, une fonction locale de similarité S(p, p + u(p)) est définie par une corrélation des valeurs de A au voisinage de p, avec celles de I au voisinage de p + u(p); et une force externe locale F(p), qui tend à mettre en correspondance les deux volumes, s'en déduit:  $F(p) = \nabla S(p, p + u(p))$ . Les forces internes obligent le champ des déplacements à obéir à un modèle de solide élastique; la situation d'équilibre vérifie alors l'expression :

$$\mu_e \nabla^2 u_x(p) + (\mu_e + \lambda_e) \frac{\partial (\nabla . u(p))}{\partial x} + F_x(p) = 0$$

donnée pour x, et les deux expressions similaires pour y et z;  $\mu_e$  et  $\lambda_e$  sont des coefficients qui règlent l'élasticité. La résolution s'effectue itérativement, de façon discrète sur le maillage de l'atlas.

Dans [BAJC-89], l'algorithme est multi-grilles ce qui présente trois avantages : la convergence est accélérée, des déformations importantes peuvent plus facilement être prises en compte, et en conséquence, la similarité locale et la cohérence globale en sont améliorées. L'approche par modèle déformable élastique est reprise dans [GEE-95a] [GEE-95b] avec une formulation bayésienne.

*Christensen, Rabbitt et Miller* [CHRI-93] [CHRI-94] proposent une seconde forme de modèle appliquée aux données volumiques, celle de fluides visqueux, plus appropriée que la première pour tenir compte de forts déplacements. La résolution itérative se traduit par l'introduction du temps, et de la vélocité *v* des déplacements :

$$v(p,t) = \frac{\partial u(p,t)}{\partial t} + v(p,t) \cdot \nabla u(p,t)$$

La situation d'équilibre s'écrit maintenant :

$$\mu_v \nabla^2 v(p,t) + (\mu_v + \beta_v) \nabla (\nabla . v(p,t)) = F(p,t) ,$$

où  $\mu_v$  et  $\beta_v$  sont des coefficients qui règlent la viscosité.

La résolution numérique est extrêmenent coûteuse en temps de calcul, y compris en 2D, et malgré une initialisation préliminaire. A en juger par les images des articles, les résultats sont bons.

# Primitive (3+1)D

Dans [FELD-96], *Feldmar, Malandain et al.* proposent une méthode de recalage volumique qui cherche à minimiser une fonctionnelle. La technique de minimisation, qui ne nécessite pas le calcul des dérivées de la fonctionnelle, s'apparente à l'algorithme de Besl et McKay (Cf. section 9.2.3).

L'originalité de leur approche est de considérer que le recalage est un problème global de dimension 4 : les 3 dimensions de l'espace des volumes A et I, et une 4<sup>ème</sup> qui correspond à l'espace des radiométries. La fonctionnelle à minimiser s'écrit :

$$E(f,g) = \sum_{p} d\left(\{f(p), g(p, A(p))\}, \mathsf{PPV}_{I}(\{f(p), g(p, A(p))\})\right)^{\frac{1}{2}}$$

où p un point 3D du volume A, A(p) la radiométrie de p dans A, f une transformation 3D entre A et I, g une fonction de requantification définie sur l'espace 4D, PPV<sub>I</sub> la fonction de plus proche voisin sur l'ensemble { (p, I(p)) }, et d une distance de l'espace 4D.

Notons la différence principale de cette méthode par rapport aux modèles volumiques déformables : la distance d'un voxel de A et de son correspondant dans I, tient compte à la fois de l'éloignement de ces points dans l'espace 3D des images, et de leur différence (1D) radiométrique.

# 9.3 Conclusion

De l'état de l'art que nous venons de dresser, il ressort que les procédures de reconnaissance par atlas mises en œuvre jusqu'à présent forment en fait deux catégories.

- Certaines procédures s'appuient sur des primitives « sous-volumiques », généralement des points d'amer ou des surfaces. Ces primitives doivent être extraites de l'image afin d'en déduire la transformation globale qui permet de plaquer un atlas sur l'image à traiter.
- D'autres procédures, « volumiques », manipulent l'ensemble des données du volume pour obtenir la transformation globale.

Dans le premier cas, l'extraction des primitives peut être automatisée, et ces primitives de l'image à traiter servent de guide au calcul de la déformation de l'atlas, et donc au positionnement de l'atlas sur l'image. Les résultats les plus prometteurs [THOM-96b] proviennent de l'utilisation conjointe des surfaces extérieures du cortex et du système ventriculaire. Néanmoins, le défaut principal de ce type de procédures réside en un guidage de la déformation restreint à quelques primitives.

Dans le second cas, cette restriction est levée. En revanche, l'implication de la radiométrie oblige à rechercher, en plus de la transformation, une correspondance radiométrique entre l'image à traiter et la référence. Le fait que la référence soit un atlas d'étiquettes rend plus délicate l'obtention de la correspondance radiométrie/étiquette, et risque de perturber l'obtention d'un résultat final correct.

# **Chapitre 10**

# Présentation générale de la procédure de reconnaissance

La procédure originale de reconnaissance des structures cérébrales que nous proposons dans cette partie se distingue des procédures existantes, dont le chapitre précédent a dressé un état de l'art.

Par rapport aux deux catégories de procédures à base d'atlas que nous avons distinguées en conclusion du chapitre précédent, notre approche est hybride : elle utilise alternativement des primitives surfaciques et volumiques.

Son originalité principale réside dans le fait qu'elle est constituée de plusieurs étapes successives de segmentation, et de mise en correspondance avec l'atlas. Pour mener à bien la reconnaissance progressive des structures anatomiques, nous nous appuyons sur leur hiérarchie naturelle dans le cerveau, sur leur relative difficulté de segmentation, et sur l'ensemble des relations spatiales qui permettent de les identifier.

Ce chapitre a pour but de présenter les grandes étapes de cette procédure sans entrer dans le détail des méthodes qu'elle fait intervenir (section 10.1), et de la justifier (section 10.2).

# **10.1 Reconnaissance séquentielle avec informations** *a priori*

# **10.1.1 Description générale**

L'attitude du clinicien d'un service de neurologie face à des images par résonance magnétique témoigne de son degré d'expertise dans ce domaine. Le fait qu'il reconnaisse facilement une structure cérébrale dans une image par résonance magnétique fait intervenir un nombre important de connaissances anatomiques qu'il a pu acquérir lors de sa pratique. Ces connaissances recouvrent la morphologie des structures, leurs positions absolue et relative, leur radiométrie approximative dans les différents modes d'acquisition, etc.

La reconnaissance par un praticien d'une structure anatomique particulière met alors en jeu l'ensemble des informations concernant cette structure. Comme certaines de ces informations sont relatives à d'autres structures, le praticien s'appuie souvent sur la reconnaissance au préalable d'une partie de ces autres structures, plus faciles à reconnaître. Par exemple, en vue axiale, l'identification de la queue du noyau caudé gauche n'est aisée que si l'atrium du ventricule latéral gauche a été repéré (Cf. figure 1.3 page 21).

Aussi, nous proposons pour la reconnaissance des structures cérébrales une démarche originale, proche de celle du praticien.

Cette démarche est séquentielle ; chaque étape a pour but de reconnaître un nouvel objet cérébral. Chaque étape s'appuie pour cela sur les objets obtenus lors des étapes précédentes et sur des connaissances anatomiques de natures différentes. Les informations de localisation et de morphologie de cet objet sont apportées par un atlas numérique et des informations symboliques sur cet objet sont exprimées relativement à des objets identifiés lors des étapes précédentes. Ces informations symboliques concernent aussi bien des relations spatiales (ensemblistes, directionnelles, de distances) que des informations de constitution ou des connaissances radiométriques relatives au type d'imagerie.

L'atlas et l'image à traiter n'ont généralement pas le même échantillonnage; le nombre de voxels dans chaque dimension ainsi que les dimensions d'un voxel sont généralement différents dans les deux volumes. À l'instar des informations symboliques, les informations en provenance de l'atlas sont exprimées dans l'espace de l'image à traiter afin de reconnaître, dans cette image, l'objet recherché. Il nous faut donc passer ces informations de l'espace de l'atlas à l'espace de l'image; ce passage est réalisé à l'aide d'un champ de déformations, actualisé à chaque étape, et tel qu'il mette en correspondance entre l'atlas et l'image l'ensemble des structures reconnues à l'issue des étapes précédentes.

La reconnaissance des objets cérébraux est donc progressive, guidée par un atlas dont la déformation est affinée à chaque étape, et repose sur la connaissance *a priori* de l'anatomie des objets, absolue ou relative.

# **10.1.2 Description d'une étape**

Une étape de la procédure vise ainsi à reconnaître un objet, et se décompose en plusieurs sousétapes que nous présentons ici de façon rapide (nous les détaillerons dans les chapitres suivants):

- la forme de l'objet portée par l'atlas est exprimée dans l'espace de l'image à l'aide du champ de déformation,
- 2. chaque information symbolique décrivant l'objet recherché en fonction de connaissances *a priori* (relations radiométriques et spatiales avec des objets déjà reconnus), est traduite sous la forme d'une image,
- 3. une région d'intérêt de l'image est déterminée par dilatation de la forme de la sous-étape 1 de telle façon que cette région contienne avec une forte probabilité l'objet recherché,
- 4. plusieurs classifications sont menées sur la radiométrie des voxels de cette région,
- 5. la fusion des informations symboliques, des classes et de l'information morphologique de l'atlas fournit une segmentation de l'objet recherché,
- la déformation spécifique à cet objet et qui le met en correspondance entre l'atlas et l'image est déterminée,
- 7. la mise en correspondance globale entre le volume de l'atlas et celui de l'image est calculée de telle façon que les objets reconnus jusqu'à cette étape comprise coïncident.

La modélisation des imperfections des informations utilisées lors de ces sous-étapes (en particulier leur imprécision et leur caractère approximatif) est effectuée à l'aide d'un formalisme flou. Ainsi, la forme des objets (sous-étape 1), les informations symboliques (sous-étape 2), les régions d'intérêt (sous-étape 3), les classifications (sous-étape 4) et les fusions (sous-étape 5) sont flous.

Comme nous avons automatisé avec succès une méthode de segmentation du cerveau par morphologie mathématique et comme notre problématique se limite aux structures internes du cerveau, nous avons choisi de commencer notre procédure de reconnaissance à partir de cette segmentation. L'initialisation du champ de déformation utilisé dès la première étape de la reconnaissance consiste en la mise en correspondance du cerveau segmenté avec son équivalent dans l'atlas.

# 10.2 Justifications de nos choix

# 10.2.1 La séquentialité

La procédure que nous proposons repose sur une séquentialité de la segmentation. Le défaut principal d'une telle approche réside dans sa sensibilité aux erreurs : si le résultat d'une étape est erroné, l'erreur va se propager au cours des étapes suivantes.

Pour éviter un tel problème, nous pouvons envisager une heuristique de segmentation moins linéaire. Plutôt que de segmenter un objet après l'autre, les objets peuvent être regroupés et la segmentation d'un groupe d'objets peut former une étape à part entière. Un critère doit alors valider l'exactitude de la segmentation d'un groupe d'objets. Si un tel critère n'est pas vérifié, d'autres méthodes de segmentation sont envisagées ; si au final, aucune méthode ne fournit de résultat acceptable alors le regroupement des objets est modifié ou un retour en arrière doit être effectué.

Une heuristique de la sorte correspond à une segmentation plus globale des structures cérébrales, donc *a priori* plus robuste qu'une approche séquentielle. Cependant, la définition d'un critère de validité non biaisé suppose que les informations sur lesquelles il s'appuie ne sont pas prises en compte dans les méthodes de segmentation. Ces dernières ne peuvent donc pas tirer parti de l'ensemble des informations disponibles concernant chaque objet.

En conséquence, notre choix s'est porté vers une procédure séquentielle qui permet d'utiliser pour la segmentation de tout objet cérébral un maximum d'informations le concernant.

L'ordre de la segmentation des structures est un facteur primordial pour garantir la robustesse d'une procédure séquentielle. Nous devons donc établir un ordre de reconnaissance des structures le plus pertinent possible. Pour cela, deux considérations entrent en jeu:

- une structure facile à segmenter et à recaler avec sa référence dans l'atlas devra être traitée en priorité car son étape n'introduira pas d'erreurs significatives dans la suite de la procédure,
- une structure sur laquelle repose une description précise d'une seconde structure sera de préférence segmentée avant cette dernière.

Ces deux considérations méritent plusieurs remarques.

Dans notre procédure, une structure se segmente facilement si les informations concernant cette structure sont nombreuses ou précises, si sa radiométrie est homogène et contraste avec celles de ses structures voisines, et si sa localisation et sa morphologie ne varient pas beaucoup d'un individu à un autre. Une fois segmentée, cette structure est plus ou moins facile à recaler avec son équivalent dans l'atlas suivant la qualité de sa segmentation, la variabilité anatomique de cette structure entre l'image et l'atlas, et le niveau de complexité de sa morphologie. A cause de l'effet de volume partiel

qui dégrade fortement les petites structures, un gage de réussite sera souvent la taille importante de la structure.

Lorsqu'un groupe de structures sont en relation, le choix de décrire l'une d'entre elles avec des informations dépendantes des autres peut sembler arbitraire ; une illustration simpliste est l'assertion « A est à gauche de B » qui ne semble pas différente de « B est à droite de A ». Pourtant, le choix d'une description n'est pas arbitraire car il dépend fortement de la facilité de segmentation des structures. Ainsi, on préfèrera exprimer les relations qui décrivent une structure délicate à segmenter à l'aide des structures qui elles, sont plus faciles à obtenir.

# 10.2.2 L'emploi du flou

La théorie des ensembles flous a offert aux traiteurs d'images un nombre important d'outils. Comme nous l'avons vu en 5.3, l'introduction de flou permet de modéliser l'imprécision inhérente aux données; en l'occurrence, pour les observations en IRM, le fait que la radiométrie de chaque voxel soit d'une part bruitée, et d'autre part affectée de volumes partiels justifie la formulation de classes floues de radiométries (sous-étape 4).

Cependant, l'utilisation de la théorie des ensembles flous en traitement d'images ne se limite pas à la prise en compte de l'imprécision des données radiométriques.

L'atlas que nous utilisons a été construit à partir d'une unique acquisition de cerveau sain et tout objet cérébral y est représenté par un ensemble non-flou de voxels (Cf. section 11.1.1). De tels ensembles vont servir de références morphologiques et spatiales et ne tiennent pourtant pas compte de la variabilité inter-individus de ce type d'informations. Les rendre flous permet de prendre en compte le caractère imprécis de leur définition dû à l'existence de variabilité morphologique [BLOC-95a] (sous-étape 1).

De même, la caractère flou de la région d'intérêt dans laquelle nous recherchons l'objet à segmenter (sous-étape 3) reflète l'imprécision de la localisation de cet objet dans l'image.

Différentes sortes d'informations spatiales au sein des images s'expriment sous forme de notions vagues [BLOC-96e]; c'est le cas par exemple des assertions « l'objet A est dans la partie supérieure de l'image » et « l'objet A est à gauche de l'objet B ». L'identification des régions de l'image associées à de telles notions de position relative doit tenir compte de leur caractère vague, et de nouveau, la théorie des ensembles flous nous apporte des solutions. Ces notions peuvent se traduire en termes d'ensembles flous et les régions correspondantes de l'image peuvent se représenter sous la forme d'images floues de telle façon que la valeur d'un point d'une image floue traduit la valeur d'appartenance de ce point à l'ensemble flou.

Les substantifs du langage courant qui ajoutent un caractère quantitatif à une information peuvent tirer parti de l'aspect numérique des valeurs d'appartenance. Ainsi « la partie **très** supérieure de l'image » ne se traduit pas par le même ensemble flou que celui de « la partie supérieure de l'image ».

Dans le cas d'informations qui ne sont explicitement ni imprécises ni vagues, la notion de flou peut quelquefois être incontournable. En effet, si une donnée de l'information est floue alors la traduction de l'information en image sera floue. Par exemple, pour une région floue d'une image l'information « à l'extérieur de » ne s'accomodera pas d'un formalisme non-flou.

Ces trois points interviennent lors de la sous-étape 2.

Lorsque l'on dispose de plusieurs informations comme pour l'objet A de l'exemple précédent, la théorie des ensembles flous met à notre disposition des opérateurs de fusion [BLOC-96c]. Effectuer de la fusion floue (sous-étape 5) présente trois avantages importants.

Le premier avantage est de pouvoir manipuler des informations élémentaires floues. La fusion peut alors tirer le meilleur parti des informations nuancées, souvent plus pertinentes que les informations booléennes comme nous venons de le voir.

Le deuxième est de pouvoir repousser l'obtention d'un résultat non-flou après avoir effectué l'enchaînement des règles de fusion. Ainsi, la finesse que nous apporte une modélisation floue de chaque information, élémentaire ou issue de fusion, est conservée tout au long du processus de fusion. Les conséquences radicales que peuvent entraîner sur le résultat final l'accumulation d'opérations booléennes sont évitées ; de plus, même l'utilisation, dès les premières étapes de fusion, d'un opérateur flou sévère ne conduit pas systématiquement à ce type d'écueil. La fusion permet également, en combinant des informations complémentaires, de lever les ambiguités qui peuvent être attachées éventuellement à un type d'informations.

Enfin, le dernier avantage de la fusion floue est de proposer un important jeu d'opérateurs flous ce qui permet de traduire naturellement des expressions telles que « l'objet A est dans la partie supérieure de l'image, **et peut-être**, à gauche de l'objet B ».

# 10.2.3 Recherche restreinte à une région d'intérêt

La sous-étape 4 consiste en des classifications menées dans une région d'intérêt de l'image. La restriction de cette dernière est motivée par le fait que la robustesse d'une classification automatique du type k-moyennes n'est garantie que sous certaines contraintes (voir section 5.2.4). En effet, la convergence de l'algorithme doit être répétée un grand nombre de fois avec des initialisations différentes pour obtenir un résultat très proche de l'optimum au sens du critère de distance ; de plus, lorsque le nombre k de classes croît, le nombre d'itérations devient vite très important.

Limiter la classification radiométrique à une région d'intérêt est un remède à la non-robustesse de l'algorithme. Il nous faut encore justifier le fait que, de par sa construction, la région d'intérêt contient bien l'objet que l'on recherche.

Comme notre procédure met progressivement en correspondance l'image et l'atlas, l'objet cérébral recherché à une étape donnée est approximativement localisé par sa référence dans l'atlas. L'erreur de localisation a trois causes :

- le champ de déformation qui permet de passer de l'atlas à l'image ne fournit qu'une estimation du passage de l'atlas à l'image,
- de plus, le champ de déformation est peut-être affecté par les erreurs qui ont pu s'accumuler lors des étapes précédentes,
- la variabilité inter-individus ne garantit pas que la morphologie et la position spatiale de la structure du patient dans l'image soit exactement similaire à cette même structure dans l'atlas.

Au vu des résultats que nous avons obtenus, la variabilité est la cause principale d'erreur. Cette variabilité est très souvent faible; une dilatation de la forme de référence s'avère suffisante pour garantir que la région d'intérêt contient effectivement l'objet recherché.

# **10.2.4** Guidage de la segmentation par les informations a priori

Guider la segmentation des structures cérébrales à l'aide d'un atlas est une démarche qui semble naturelle, leur organisation étant globalement invariante. Les seuls écarts entre l'image et son atlasmodèle sont dus à quatre facteurs :

- la différence de repérage spatial,

- la radiométrie *a priori* inconnue des structures dans l'image,
- la présence éventuelle d'une pathologie,
- la variabilité morphologique intra-individus.

L'utilisation d'informations a priori va nous aider à tenir compte de ces écarts.

Le premier facteur d'écart s'élimine en effectuant un recalage global de l'image pour qu'elle s'adapte au mieux à l'atlas; c'est le prétraitement que nous mentionnons en fin de section 10.1.2, véritable point de départ de notre procédure de reconnaissance. Les premières informations *a priori* qui nous servent sont donc celles qui nous permettent de segmenter le cerveau à l'aide d'opérateurs morphologiques (section 7.2). La correspondance globale entre le cerveau-image et le cerveau-atlas ne pose alors plus de problème.

Pour que les caractéristiques radiométriques des structures cérébrales puissent intervenir dans la procédure de reconnaissance sous forme d'informations, nous devons être à même de les apprendre au cours de cette même procédure. Lors de ces premières étapes, ces caractéristiques sont inconnues; néanmoins, le type d'acquisition de l'image à traiter étant connu, nous pouvons utiliser une information *a priori* sur le caractère clair ou foncé des structures que l'on recherche. Même si cette information est moins précise que la connaissance d'une radiométrie moyenne, elle nous permet de rendre plus robuste les premières étapes, celles justement qui nous permettent d'accéder aux caractéristiques radiométriques précises.

Une de nos hypothèses de travail est de ne traiter que des cerveaux sains. Cela limite considérablement les écarts de localisation spatiale et de morphologie entre une structure décrite dans l'atlas et cette même structure dans l'image. De plus, la cohérence de l'organisation cérébrale est alors garantie et les informations *a priori* liées à cette organisation le sont également.

Le dernier type d'écart concerne la variabilité morphologique intra-individus. Grâce à la construction d'une correspondance progressive entre l'image et l'atlas, l'écart n'est plus absolu mais relatif et par conséquent faible. Les informations *a priori* de localisation et de morphologie en deviennent plus pertinentes.

A une étape donnée, la segmentation est guidée par un certain nombre d'informations *a priori*; que ce soit celles qu'apportent l'atlas ou les segmentations des étapes précédentes ou que ce soit des informations symboliques, de leur combinaison naît une connaissance accrue de la structure à segmenter.

Ce guide est non seulement le support de notre procédure de reconnaissance, mais aussi un cadre formel qui tire parti de façon uniforme des multiples connaissances que nous pouvons injecter dans notre procédure.

# 10.3 Conclusion

Nous avons dit dans l'introduction de ce chapitre que l'originalité principale de notre méthode réside dans sa séquentialité. Cette originalité a de nombreuses conséquences positives.

Cette procédure n'a pas pour but de segmenter une structure cérébrale donnée; elle traite l'ensemble des structures, mais chaque structure successivement. Cela permet ainsi la prise compte de leur diversité, et donc de la spécificité de chacune.

Le mode de segmentation peut différer en fonction de la structure recherchée : la méthode de segmentation peut changer, les informations introduites aussi. De plus, la quantité des informations que nous pouvons faire intervenir augmente au fur et à mesure des étapes ; la segmentation de structures « difficiles » n'est plus impossible.

Enfin, en fonction du type d'imagerie utilisée, la lecture (ou importance relative) des structures dans l'image n'est pas la même : l'ordre des segmentations peut alors être adapté.

Nous ne cherchons pas non plus à obtenir directement une correspondance globale entre l'atlas et l'image à traiter.

Cette correspondance se construit progressivement. A chaque étape, une nouvelle structure est reconnue. La transformation qui met cette structure en correspondance avec sa référence dans l'atlas nous permet d'affiner la transformation globale, issue de l'étape précédente. Conséquemment, la mise en correspondance est elle-aussi progressive. Au final, la déformation est cohérente avec l'ensemble des structures reconnues ; l'image à traiter s'identifie à l'atlas, aucune connaissance n'est extrapolée.

Notons que la segmentation obtenue à l'issue d'une étape peut faire l'objet d'une validation par un praticien, qui pourrait éventuellement corriger le résultat avant que la procédure ne reprenne.

Par rapport aux méthodes existantes de mise en correspondance d'un atlas avec une image, celleci permet une introduction très intuitive d'informations *a priori*, et alterne déformation surfacique et extension à la déformation globale, pour donner finalement une reconnaissance complète des structures cérébrales.

# Chapitre 11

# Champs discrets de déformations entre atlas et image

Dans notre procédure, les informations portées par l'atlas sont transmises à l'image après qu'elles sont transformées par un champ de déformation. Ce dernier permet de mettre en correspondance ces informations avec l'image particulière à traiter, et s'appuie, à une étape donnée, sur les structures déjà reconnues.

Cependant, ces informations sont imprécises. Elles décrivent la localisation et la morphologie de structures cérébrales de référence, et ne traduisent ni une anatomie moyenne ni une anatomie probabiliste. Afin de tenir compte de la variabilité inter-individus des structures cérébrales, elles sont utilisées sous forme d'informations floues pour la reconnaissance.

Le champ de déformation lui-même n'a donc pas pour objectif d'être précis. Contrairement à la plupart des approches citées en section 9.2 où la reconnaissance des structures se déduit directement du champ de déformation, dans notre approche, ce dernier est seulement un outil, un guide qui permet de mener à bien la reconnaissance des structures anatomiques de l'image, en fournissant leur localisation approximative.

Construit à partir des données (ou plus exactement, à partir des surfaces des données et des déformations que ces surfaces doivent subir pour que l'atlas s'adapte aux données), il n'est pas extrinsèque à ces données. En particulier, il doit respecter leur topologie. Un objet, inclus dans un autre dans l'atlas, doit présenter cette même propriété dans l'image; de même, deux objets adjacents dans l'atlas doivent le rester dans l'image.

De plus, ce champ doit satisfaire à la fois à de fortes déformations globales, et à de petites déformations locales ; cela est facilité par le fait que son calcul est progressif. Au début de la procédure, les déformations importantes sont établies, puis le champ est modifié, affiné, pour qu'il tienne compte de déformations plus faibles, imprimées par des structures plus petites, et de moindre importance du point de vue de l'organisation anatomique.

Dans ce chapitre, nous présentons tout d'abord en section 11.1 la structure d'un champ de correspondance, mieux adapté à notre problématique que ne l'est un champ de déformation, et à partir duquel une déformation peut être déduite. Nous montrons aussi que, malgré sa nature discrète, le champ de correspondance peut obéir aux contraintes topologiques. En section 11.2, nous proposons une méthode simple de calcul de la correspondance entre deux surfaces par recalage, et en section 11.3, une façon simple d'inférer sur l'ensemble du volume une correspondance discrète, continue et topologiquement correcte.

# 11.1 Déformation Atlas/Image

# 11.1.1 Constitution de l'atlas

La manipulation d'un atlas dans notre procédure de segmentation nécessite que les objets cérébraux qu'il décrit aient une morphologie et une localisation suffisamment significatives de l'anatomie du plus grand nombre de patients. Cela explique que l'utilisation d'atlas trop schématiques ou trop peu précis n'ait pas été retenue ; en particulier, celui de Talairach présentait un trop petit nombre de coupes (Cf. section 9.1.2).

L'atlas que nous employons a été dessiné manuellement à l'aide de *3Draw*, logiciel que nous avons écrit originellement pour la visualisation d'images volumiques dans leurs trois plans de coupe (voir en figure 9.1). Comme nous l'avons remarqué en section 2.3.2, la compréhension de la morphologie d'une structure est délicate si l'on se contente d'appréhender le volume avec un plan de coupe unique ; nous avons donc ici pu tirer parti de la représentation simultanée du volume en coupes axiale, coronale et sagittale pour segmenter les différents objets cérébraux.

L'image que nous avons utilisée provient de l'hôpital *La Timone* de Marseille. Acquise en  $T_1$ , elle montre une tête dont le cerveau est sain. Les voxels sont anisotropes : chaque coupe axiale est composée de 256 × 256 voxels de taille 1 × 1 mm, et le volume possède 124 coupes axiales d'épaisseur environ 1,3 mm. La figure 11.1 montre, sur une coupe axiale, l'image originale (a) et les objets de l'atlas (b). Chaque objet de l'atlas a reçu une étiquette particulière, qui permet de le distinguer des autres objets; les objets identifiés dans l'atlas sont les suivants

- le cerveau,

- pour le système ventriculaire :

- les ventricules latéraux,
- les trous de Monro,
- le troisième ventricule,
- l'aqueduc de Sylvius,
- le quatrième ventricule,

pour les noyaux centraux :

- les noyaux caudés,
- les putamens,
- les thalami,

pour les commissures :

- la commissure antérieure,
- le fornix.

Nous aurions pu choisir un atlas numérique déjà construit, représentant une anatomie « moyenne » ou « probabiliste » ; cela aurait peut-être amélioré nos résultats de reconnaissance. En optant pour un atlas issu d'une acquisition unique, nous montrons qu'un modèle suffit pour obtenir de bons résultats par notre procédure, puisqu'elle tient compte de l'inévitable variabilité anatomique inter-individus.



FIG. 11.1 – Coupe axiale de l'image-modèle et de l'atlas

L'atlas que nous utilisons est construit à partir d'une image-modèle tridimensionnelle en  $T_1$ , dont une coupe est extraite (a); particulièrement bien contrastée, la segmentation manuelle des différentes structures cérébrales en a été facilitée. Seules quelques structures sont montrées en (b) sur la coupe de l'atlas, équivalente à (a).

# 11.1.2 Vecteurs de correspondance et de déformation

Nous souhaitons pouvoir récupérer dans l'espace de l'image à traiter les informations portées par l'atlas. Comme nous avons décidé de travailler en discret, pour chaque voxel de l'image nous devons connaître sa correspondance dans l'atlas.

Les notations que nous allons utiliser sont regroupées dans les tableaux 11.1 et 11.2; les propriétés triviales qui en résultent sont données dans le tableau 11.3.

notation	signification	
Ι	image à traiter	
A	atlas	
S	I ou A	
x	axe correspondant aux coupes coronales	
y	axe correspondant aux coupes sagittales	
z	axe correspondant aux coupes axiales	
$n_x(S) \in \mathbb{N}$	nombre de coupes coronales de S	
	(idem avec $y$ pour sagittales, et $z$ pour axiales)	
$d_x(S) \in \mathbb{R}$	distance entre les coupes coronales de $S$	
	(idem avec $y$ pour sagittale, et $z$ pour axiale)	
v(S)	voxel de S	
$X(v(S)) \in \mathbb{N}$	indice de la coupe coronale de $v(S)$	
	(idem avec $y$ pour sagittales, et $z$ pour axiales)	
	$ \begin{cases} x = X(v(S)) \\ V(v(S)) \end{cases} $	
v(S, x, y, z)	voxel $v(S)$ de S tel que $\begin{cases} y = Y(v(S)) \\ Z(-(C)) \end{cases}$	
<b>I</b> <i>T</i> ( <i>C</i> )	(z = Z(v(S)))	
V(S)	ensemble des voxels de S	
$R(S) \subset V(S)$	ensemble de voxels de $S$	
$\mathcal{R}(S)$	ensemble des $R(S)$	
$\mathcal{S}(\overline{x,y,z)}$	l'information portée par le voxel $v(S, x, y, z)$	

TAB. 11.1 – Notations pour l'expression de la structure d'une image

Une fonction de correspondance (ou de passage) associe à un point flottant du volume de l'image I à traiter un point flottant de l'atlas A. Avec la restriction de cette définition aux volumes spatiaux (cubes des données), la fonction de correspondance  $f_E$  associe à un point de E(I) un point de E(A); la notation E(S), avec S = IouA, indique que nous considérons chaque espace avec une métrique liée au système d'indiçage de S. Nous avons :

$$f_E: E(I) \to E(A) . \tag{11.1}$$

Nous excluons ainsi toute possibilité qu'un point du volume de l'image à traiter ait pour correspondant un point extérieur au volume de l'atlas. Cette restriction, purement arbitraire, mais très pratique pour garantir que nous ne « sortirons » jamais du volume des images, n'est généralement pas réaliste. En effet, aucune raison ne justifie que les deux volumes que nous manipulons représentent exactement la même scène, c'est-à-dire le même volume d'acquisition. Il nous faut donc émettre une hypothèse pour que la fonction de correspondance soit utilisable telle qu'elle a été définie.

Nous allons pour cela supposer que l'image à traiter contient l'intégralité du volume cérébral. Comme l'atlas que nous avons construit comporte lui aussi ce volume, la fonction de correspon-

notation	signification
p(S)	point flottant de l'espace de $S$
$E_m(S) \subset \mathbb{R}^3$	espace en métrique réelle (millimétrée)
	restreint au volume de S
$X_m(p(S)) \in \mathbf{R}$	coordonnée en $x$ de $p(S)$ dans $E_m(S)$
	$ (x = X_m(p(S))) $
$p_m(S, x, y, z) \in E_m(S)$	point $p(S)$ de S tel que $\begin{cases} y = Y_m(p(S)) \end{cases}$
	$z = Z_m(p(S))$
$f_{E_m}$	fonction de correspondance de $E_m(I)$ à $E_m(A)$
$E(S) \subset \mathbb{R}^3$	espace en métrique liée aux indices de $S$
	restreint au volume de S
$X(p(S)) \in \mathbb{R}$	coordonnée en $x$ de $p(S)$ dans $E(S)$
	$\int x = X(p(S))$
$p(S, x, y, z) \in E(S)$	point $p(S)$ de S tel que $\begin{cases} y = Y(p(S)) \end{cases}$
	z = Z(p(S))
$f_E$	fonction de correspondance de $E(I)$ à $E(A)$
$f_V$	restriction de $f_E$ à $V(I)$
$F_V$	ensemble des $f(v(I))$
$F_R \subset F_V$	ensemble des $f(v(I))$ avec $v(I) \in R(I)$

TAB. 11.2 – Notations pour l'expression de champs discrets de déformation

TAB. 11.3 – Propriétés résultant des notations

$X(v(S)) \in 0n_x(S) \Leftrightarrow 1$ idem avec y et z
$V(S) = \{ v(S, x, y, z) \}$ et $card(V(S)) = n_x(S).n_y(S).n_z(S)$
$\{ V(S) , \emptyset \} \in \mathcal{R}(S)$
$X_m(p(S)) = d_x(S) X(p(S))$ idem avec y et z
$p(S, x, y, z) = p_m(S, d_x(S) x, d_y(S) y, d_z(S) z)$
$\Leftrightarrow \frac{1}{2} \le X(p(S)) \le n_x(S) \Leftrightarrow \frac{1}{2}$ idem avec y et z
$(p(S, x, y, z) \text{ tel que } (x, y, z) \in \mathbb{N}^3) \Leftrightarrow (p(S, x, y, z) = v(S, x, y, z))$

dance peut être valide sur le volume cérébral ; et comme nous ne nous intéressons pas à l'extérieur du cerveau, nous pouvons tolérer que la correspondance des points de l'image extra-cérébraux soit incorrecte mais valide de force la restriction de la formule (11.1).

Le volume tridimensionnel d'une image S fait l'objet de deux métriques différentes : l'espace  $E_m(S)$  où les coordonnées des points s'expriment en millimètres, donc dans un repère en taille réelle, et l'espace E(S) où les points ont des coordonnées rapportées à l'échelle de l'échantillonnage. La métrique de E(S) nous permet d'assurer une adéquation entre la notation v(S, x, y, z) du voxel de coordonnées entières (x, y, z), et la notation p(S, x, y, z) d'un point de coordonnées en virgule flottante ; naturellement, l'origine des espaces métriques est fixée au centre du voxel d'indices (0, 0, 0).

Connaissant la fonction de correspondance  $f_E$  de E(I) vers E(A), la fonction de correspondance équivalente, mais définie de  $E_m(I)$  vers  $E_m(A)$ , se déduit facilement. Pour connaître le correspondant  $p'_m(A)$  par  $f_{E_m}$  d'un point  $p_m(I)$ , soit:

$$p'_m(A) = f_{E_m}\left(p_m(I)\right) ,$$

on peut former le correspondant p' par  $f_E$  du point p:

$$p'(A) = f_E\left(p(I, \frac{X_m(p_m(I))}{d_x(I)}, \frac{Y_m(p_m(I))}{d_y(I)}, \frac{Z_m(p_m(I))}{d_z(I)})\right),$$

pour aboutir aux coordonnées de  $p'_m$ :

$$\begin{cases} X_m(p'_m(A)) = d_x(A) X(p'(A)) \\ Y_m(p'_m(A)) = d_y(A) Y(p'(A)) \\ Z_m(p'_m(A)) = d_z(A) Z(p'(A)). \end{cases}$$
(11.2)

Calculer la correspondance de  $E_m(I)$  à  $E_m(A)$  revient à calculer celle de E(I) à E(A); nous pouvons donc nous contenter de travailler dans les espaces de l'image et de l'atlas, dont les métriques respectives sont liées aux indiçages des voxels de ces volumes.

Notons enfin qu'un vecteur de déformation s'exprime suivant :

$$\overrightarrow{f_{E_m}}(p_m(I)) = f_{E_m}(p_m(I)) \Leftrightarrow p_m(I).$$
(11.3)

L'équivalence entre déformation et correspondance étant triviale, nous ne manipulons par la suite que la fonction de correspondance.

# **11.1.3** Champ de correspondance

Nous souhaitons pouvoir rapporter dans l'image des informations en provenance de l'atlas. Comme l'image à traiter est échantillonnée, nous devons évaluer, pour chaque voxel de cette image, les informations correspondantes de l'atlas. Pour cela, nous nous appuyons donc sur la correspondance image/atlas.

### Définition

Rappelons que notre but n'est pas de chercher à calculer la correspondance exacte entre les volumes de l'image à traiter et de l'atlas, mais d'établir une correspondance approximative. En particulier, notre démarche peut se limiter à la connaissance de  $f_E$  sur un ensemble d'échantillons discrets de I.

Aussi, nous appellons champ de correspondance entre I et S tout ensemble  $\{f_E(p(I))\}$ , où  $f_E$  est défini de E(I) à E(A), et où les p(I) sont les nœuds d'un échantillonnage en trame cubique de I.

# Choix entre maillage et pavage

Une première idée est de définir un champ de correspondance sur les nœuds de la trame du maillage de l'image à traiter, ou dit autrement, de considérer les p(I) tels que :

$$\begin{array}{ll} \left(\begin{array}{c} X(p(I)) = \Leftrightarrow \frac{1}{2} + i & \text{où} & i = 0..n_x(I) \\ Y(p(I)) = \Leftrightarrow \frac{1}{2} + j & \text{où} & j = 0..n_y(I) \\ Z(p(I)) = \Leftrightarrow \frac{1}{2} + k & \text{où} & k = 0..n_z(I) \end{array} \right)$$

Si  $f_E$  était connue sur E(I) et continue, le volume d'un voxel se transformerait en une région de l'atlas qui ne coïnciderait pas *a priori* avec l'échantillonnage de l'atlas ( $f_E(p(I)) \in \mathbb{R}^3$ ). Or nous nous restreignons à une connaissance de  $f_E$  discrète, où seuls les correspondants des sommets des voxels de I sont connus.

En première approximation, nous pourrions considérer que la région de A correspondant à un voxel de I est le polyèdre formé par les huit correspondants des sommets du voxel ; ce polyèdre recouvre, en tout ou en partie, un certain nombre de voxels de l'atlas, et n'a pas de raison *a priori* d'être parallélépipédique. L'information portée par le voxel de l'image à traiter peut être alors approchée par la contribution des informations de chaque voxel de l'atlas, et pondérée par leur contribution volumique à la région. Nous n'avons pas choisi cette méthode, trop coûteuse en temps de calcul.

Comme notre atlas a été construit à partir d'une acquisition de taille classique, sa résolution est comparable à celle des acquisitions IRM que nous possédons. Par conséquent, la région de l'atlas, correspondant au volume d'un voxel de l'image à traiter, est souvent de l'ordre de la taille du voxel.

Une seconde idée, très réductrice d'un point de vue géométrique, est de considérer que le volume d'un voxel de I se transforme par la fonction de correspondance en un point flottant de l'atlas : le correspondant par  $f_E$  du centre du voxel de I (cette approximation est aussi utilisée dans [THUR-93]).

Cette seconde idée revient à définir le champ de correspondance sur les centres du pavage de l'image à traiter, ou dit autrement, de considérer uniquement les p(I) tels que :

$$\begin{cases} X(p(I)) = i & \text{où} \quad i = 0..n_x(I) \\ Y(p(I)) = j & \text{où} \quad j = 0..n_y(I) \\ Z(p(I)) = k & \text{où} \quad k = 0..n_z(I) \end{cases}$$

Le champ de correspondance est tout simplement réduit à V(I).

# **Transfert d'informations**

L'information donnée par l'atlas pour le voxel v(I, i, j, k) peut être alors :

- soit l'information du voxel de l'atlas le plus proche de  $f_E(v(I, i, j, k))$ ,
- soit, de façon plus fine, une valeur interpolée de façon trilinéaire, à partir des informations des huit voxels de l'atlas entourant le point flottant  $f_E(v(I, i, j, k))$ .

Ces deux options de calcul de l'information en provenance de l'atlas sont suffisamment satisfaisantes, puisque nous ne souhaitons obtenir que des informations approximatives. Le champ de correspondance est défini de chaque voxel de l'image à traiter vers un point flottant de l'atlas, et le champ de correspondance est ainsi réduit à  $F_V$  d'après les notations du tableau 11.2.

Notons  $w \in \mathbb{Z}$  l'arrondi entier inférieur d'un réel w:

$$\underline{w} \le w < \underline{w} + 1 \,,$$

et formons:

$$p(A, x, y, z) = f_E(v(I, i, j, k))$$

Pour la première option, l'information récupérée s'écrit de façon simple :

$$\mathcal{I}(i, j, k) = \mathcal{A}(\underline{x}, y, \underline{z}).$$
(11.4)

La seconde option est moins grossière que la première, mais d'exécution un peu moins rapide. Avec la fonction d'interpolation ntp définie par :

$$\operatorname{ntp}(a,b,c) = a + c(b \Leftrightarrow a) ,$$

il vient:

$$\begin{array}{l} \mathcal{A}(\underline{x},\,y,\,\underline{z}\,) &= \operatorname{ntp}(\,\mathcal{A}(\underline{x},\,\underline{y},\,\underline{z}\,),\,\mathcal{A}(\underline{x},\,\underline{y}\,+\,1,\,\underline{z}\,),\,y \Leftrightarrow \underline{y}\,) \\ \mathcal{A}(\underline{x}\,+\,1,\,y,\,\underline{z}\,) &= \operatorname{ntp}(\,\mathcal{A}(\underline{x}\,+\,1,\,\underline{y},\,\underline{z}\,),\,\mathcal{A}(\underline{x}\,+\,1,\,\underline{y}\,+\,1,\,\underline{z}\,),\,y \Leftrightarrow \underline{y}\,) \\ \mathcal{A}(x,\,y,\,\underline{z}\,) &= \operatorname{ntp}(\,\mathcal{A}(\underline{x},\,y,\,\underline{z}\,),\,\mathcal{A}(\underline{x}\,+\,1,\,y,\,\underline{z}\,),\,x \leftrightarrow \underline{x}\,) \\ \mathcal{A}(\underline{x},\,y,\,\underline{z}\,+\,1\,) &= \operatorname{ntp}(\,\mathcal{A}(\underline{x}\,,\underline{y},\,\underline{z}\,+\,1\,),\,\mathcal{A}(\underline{x}\,,\underline{y}\,+\,1,\,\underline{z}\,+\,1\,),\,y \leftrightarrow \underline{y}\,) \\ \mathcal{A}(\underline{x}\,+\,1,\,y,\,\underline{z}\,+\,1\,) &= \operatorname{ntp}(\,\mathcal{A}(\underline{x}\,+\,1,\,\underline{y}\,,\underline{z}\,+\,1\,),\,\mathcal{A}(\underline{x}\,+\,1,\,\underline{y}\,+\,1,\,\underline{z}\,+\,1\,),\,y \leftrightarrow \underline{y}\,) \\ \mathcal{A}(x,\,y,\,\underline{z}\,+\,1\,) &= \operatorname{ntp}(\,\mathcal{A}(\underline{x}\,,y,\,\underline{z}\,+\,1\,),\,\mathcal{A}(\underline{x}\,+\,1,\,y,\,\underline{z}\,+\,1\,),\,x \leftrightarrow \underline{x}\,)\,, \end{array}$$

et au final :

$$\mathcal{I}(i, j, k) = \operatorname{ntp}(\mathcal{A}(x, y, \underline{z}), \mathcal{A}(x, y, \underline{z}+1), z \Leftrightarrow \underline{z}).$$
(11.5)

# 11.1.4 A propos de topologie

Lors de l'exécution de notre procédure, nous allons segmenter différentes structures cérébrales ; elles ont toutes, de par leur définition anatomique, une cohérence spatiale.

### Contrainte de correspondance et propriétés des objets

Comme nous allons le voir dans les deux sections qui suivent (11.2 et 11.3), nous allons manipuler le champ de correspondance de façon discrète, et lors de ces manipulations, nous ne ferons pas intervenir de contraintes homotopiques.

Le problème principal que nous allons rencontrer est de garantir qu'un voxel de l'image, compris dans le volume d'une structure, ait pour correspondant un point du volume équivalent de cette structure dans l'atlas. Le champ de correspondance doit donc vérifier cette contrainte.

Dans ce but, nous définissons plusieurs propriétés que tout objet, segmenté à une étape de la procédure, doit vérifier :

- il est composé d'une unique composante 18-connexe,
- il n'a ni trou ni tunnel,
- il est inclus entièrement dans un objet englobant.

Pour le cerveau, premier objet segmenté, l'objet englobant est la région extra-cérébrale; pour un ventricule latéral, deuxième objet segmenté, l'objet englobant est le cerveau, etc.

## Structure de données des objets

Sous la contrainte de correspondance, nous devons mettre en place une structure de données qui nous permette de distinguer dans la description d'un objet (qu'il appartienne à l'image à traiter ou à l'atlas) son intérieur et son extérieur.

De plus, il nous faut tenir compte du fait que, au cours de la procédure de reconnaissance, la caractérisation de l'intérieur et de l'extérieur d'un objet se modifie, lorsqu'un nouvel objet s'inclut spatialement dans le premier.

Dans la suite de cette partie, nous appellons :

- objet, un ensemble de voxels qui forme une unique composante connexe, et dans laquelle on distingue les parties suivantes,
- surface de l'objet (notée surf), l'ensemble de ses voxels qui ont au moins un voisin hors de l'objet (au sens de la 18-connexité),
- intérieur de l'objet (noté *int*), ou intérieur strict de l'objet, l'ensemble de ses voxels qui n'appartiennent pas à sa surface,
- surface interne de l'objet (notée sur f int), l'ensemble des voxels de sa surface qui sont voisins (au sens de la 18-connexité) d'un voxel d'un éventuel trou de l'objet,
- surface externe de l'objet (notée sur fext), l'ensemble des voxels de la surface de l'objet qui ne font pas partie de sa surface interne,
- intérieur large de l'objet (noté *intlar*), la réunion de son intérieur strict et de sa surface interne.

Ainsi pour un objet O, on a :

 $\begin{array}{l} O = surf(O) + int(O) \\ surf(O) = surfint(O) + surfext(O) \\ intlar(O) = int(O) + surfint(O) \\ O = surfext(O) + intlar(O) \end{array}$ 

Pour former l'objet de cette structure, nous distinguons sa surface de son intérieur.

En l'absence de trous et de tunnels, sa surface s'apparente à la surface externe (la surface interne est vide) ; de plus, l'objet étant connexe, la surface forme une unique composante connexe. L'intérieur large, quant à lui, s'identifie à l'intérieur (strict) ; et il forme aussi une unique composante connexe.

L'objet est stocké dans une image résultat ; la figure 11.2 illustre cette procédure : il s'agit en (a) du stockage de l'objet cerveau, et en (b) de celui de l'objet ventricule latéral gauche.

Comme nous le verrons dans le chapitre suivant (en section 12.5.4), nous garantissons que tout ajout d'objet dans l'image résultat ne peut pas empiéter sur la surface externe d'un objet déjà présent. La surface externe d'un objet, une fois apparue, ne sera donc jamais modifiée lors de la procédure.

En revanche, le nouvel objet peut appartenir à l'intérieur large d'un objet déjà segmenté ; dans ce cas, l'intérieur et la surface interne de ce dernier sont actualisés, afin de ne pas contenir de voxels du nouvel objet. Ainsi dans l'image (b) de la figure 11.2, la prise en compte de l'objet ventricule latéral gauche (noté  $O_{VTLg}$ ) fait apparaître un trou, et donc une surface interne (4), pour l'objet cerveau (noté  $O_{ENC}$ ), dont l'intérieur (3) est également mis à jour.

Pour reconstituer une structure à partir de sa description sous forme d'objet, il suffit d'effectuer un bouchage de trou, et de fusionner surface et intérieur. Ainsi, pour l'objet ventricule latéral gauche qui n'a pas de trou :  $VTLg = surf(O_{VTLg}) + int(O_{VTLg})$ , et pour l'objet cerveau qui a un trou dû à l'objet précédent :  $A\_ENC = VTLg + surf(O_{ENC}) + int(O_{ENC})$ .

### Expression de la contrainte de correspondance

Cette représentation, qui distingue pour chaque objet sa surface externe de son intérieur large, et les trois propriétés que nous imposons à chaque objet, nous permettent d'exprimer la contrainte de correspondance que le champ doit vérifier.



FIG. 11.2 – Structure de données des objets segmentés

La coupe (a) montre la structure de données de l'objet résultant d'une segmentation, et la coupe (b), l'actualisation de cette structure de données, consécutive à la prise en compte d'un second objet, inclus dans le premier. Le code des niveaux de gris employé pour cette figure est, du plus foncé au plus clair : (1) en noir, le fond de l'image résultat, région extra-cérébrale, (2) en très foncé, la surface externe de l'objet décrivant le cerveau, (3) en foncé, son intérieur, (4) en clair, sa surface interne, (5) en très clair, la surface externe de l'objet décrivant le ventricule latéral gauche, (6) en blanc, l'intérieur de ce nouvel objet.

Elle s'écrit:

- 1. les voxels de la surface externe d'un objet dans l'image à traiter ont pour correspondants des voxels de la surface externe de l'objet équivalent dans l'atlas ;
- 2. les voxels de l'intérieur large d'un objet dans l'image à traiter ont pour correspondants des voxels de l'objet équivalent dans l'atlas.

La dernière assertion est assez souple; en particulier, un voxel de l'intérieur d'un objet dans l'image à traiter peut avoir pour correspondant dans l'atlas un voxel surfacique (de la surface externe ou d'une surface interne).

Nous aurions pu restreindre cette assertion aux voxels de l'intérieur strict, et ajouter que les voxels d'une surface interne aient pour correspondants des voxels de la surface interne équivalente dans l'atlas. Cela n'est cependant pas nécessaire à la satisfaction de la contrainte de correspondance.

Afin de respecter les trois conditions ennoncées, le principe de mise en correspondance que nous exposons traite séparément les voxels des surfaces externes et les voxels des intérieurs larges.

# 11.2 Mise en correspondance surfacique

A chaque étape de notre procédure séquentielle de segmentation, nous reconnaissons un nouvel objet. Cet objet doit être mis en correspondance avec sa définition dans l'atlas. La première partie de

cette mise en correspondance se limite aux voxels de la surface externe de l'objet. La seconde partie (section 11.3) étend la mise en correspondance à l'intérieur large de l'objet.

# 11.2.1 Recalage

Nous cherchons le sous-ensemble de  $F_V$  défini sur les voxels de la surface externe de l'objet segmenté dans l'image à traiter; cette première partie s'apparente à du recalage non-rigide. Il faut que nous trouvions pour chaque voxel de la surface son correspondant sur la surface définie dans l'atlas, et comme nous l'avons vu en section 11.1.2, nous pouvons ignorer l'anisotropie de l'image et de l'atlas.

De nombreuses techniques de recalage existent [VANE-93]. Beaucoup sont coûteuses en temps de calcul, le recalage de formes complexes n'étant pas un problème facile. Nous avons opté pour une technique simple et rapide ; notre but n'est pas d'avoir un recalage précis mais seulement approximatif. Nous avons mis en œuvre dans ce but un recalage en trois temps :

- 1. tout d'abord, un recalage rigide est réalisé pour donner à chaque point de la surface externe de l'objet segmenté un correspondant dans l'atlas ;
- 2. ensuite, nous susbtituons à chaque correspondant son plus proche voisin sur la surface extérieur de l'objet dans l'atlas ;
- 3. enfin, nous régularisons l'ensemble de ces correspondants sous la contrainte qu'ils demeurent sur la surface externe (cette dernière étape est décrite dans la section 11.2.2 suivante).

Les deux premières étapes sont illustrées en figure 11.3.



(a)

(b)

FIG. 11.3 – Recalage surfacique

Les images montrent, sur une coupe de l'IRM qui a servi à constituer l'atlas, donc dans l'espace de l'atlas, les correspondants (représentés en blanc) des voxels de la surface externe du cerveau de l'image à traiter; l'image (a) ne prend en compte qu'un recalage rigide (étape 1 seule) tandis que dans l'image (b) une affectation à leur plus-proche voisin sur la surface externe du cerveau de référence a été rajoutée (étape 2).

Nous avons choisi d'utiliser une technique de recalage très rudimentaire : une simplification de la méthode d'égalisation des moments. Cette dernière ne donne pas de résultats corrects, les axes d'inertie n'étant pas souvent significatifs de la morphologie des structures cérébrales.

Pour l'objet segmenté dans l'image et l'objet de référence dans l'atlas, nous calculons leur centre de masse ainsi que leur matrice des moments. Nous effectuons ce calcul respectivement dans E(I) et E(A), c'est-à-dire en coordonnées liées à l'indiçage respectif de chaque volume.

Notons S = I ou A, O(S) l'objet, m(O(S)) son centre de masse, et M(O(S)) sa matrice d'inertie telle que :

$$M(O(S)) = \begin{pmatrix} m_{xx}(O(S)) & m_{xy}(O(S)) & m_{xz}(O(S)) \\ m_{xy}(O(S)) & m_{yy}(O(S)) & m_{yz}(O(S)) \\ m_{xz}(O(S)) & m_{yz}(O(S)) & m_{zz}(O(S)) \end{pmatrix},$$

où les coefficients se calculent suivant:

$$m_{xy}(O(S)) = \left(\frac{1}{\operatorname{card}(O(S))} \sum_{v(S) \in O(S)} X(v(S)) Y(v(S))\right) \Leftrightarrow X(m(O(S))) Y(m(O(S))).$$

La transformation de recalage simplifié est :

$$(T_A \circ H \circ T_I),$$

où  $T_A$  et  $T_I$  sont des translations définies respectivement par les vecteurs m(O(A)) et  $\Leftrightarrow m(O(I))$ , et où H est une transformation affine de coefficients d'échelle :

$$\sqrt{\frac{m_{xx}(O(A))}{m_{xx}(O(I))}}, \ \sqrt{\frac{m_{yy}(O(A))}{m_{yy}(O(I))}} \text{ et } \sqrt{\frac{m_{zz}(O(A))}{m_{zz}(O(I))}},$$

respectivement sur les axes x, y et z.

Ainsi, le recalage comporte uniquement translations et facteurs d'échelle ; aucune rotation n'est mise en œuvre. Pour que le résultat du recalage soit satisfaisant, cela suppose que l'image à traiter et l'atlas aient des axes relativement proches. Cela est souvent réalisable dans la mesure où la géométrie de l'acquisition est connue.

Ce recalage simpliste suppose en fait que les axes d'inertie des objets cérébraux coïncident avec les directions d'échantillonnage de l'image et de l'atlas, et qu'il n'y a donc pas lieu d'effectuer une rotation. Cette hypothèse, très grossière, n'est que partiellement compensée par l'étape suivante du recalage ; le résultat correct obtenu à l'issue des deux étapes justifie *a posteriori* cette démarche.

La transformation est appliquée à chaque voxel de la surface externe de l'objet dans l'image à traiter et indique donc pour chaque voxel un point flottant de l'espace  $E_A$ . Afin que le correspondant obtenu au final soit un voxel de la surface externe de l'objet dans l'atlas, au point flottant est substitué le voxel qui est le plus proche voisin sur cette surface du voxel qui contient ce point.

Afin d'établir cette substitution, nous avons précalculé une carte de plus proche voisin; pour la surface considérée, cette carte donne pour chaque voxel de l'atlas son plus proche voisin sur la surface. Le calcul de cette carte est réalisé simultanément au calcul de la carte de distance à la surface par propagation de chanfrein. Nous avons pour cela modifié l'algorithme du chanfrein [BORG-86].

Notons D la carte de distance, PPV la carte de plus proches voisins,  $Ch_{forth}$  et  $Ch_{back}$  les deux demi-chanfreins, *i* un indice de voisinage dans le chanfrein,  $ch_i$  le coefficient de chanfrein qui lui est associé dans Ch, et  $(x_i, y_i, z_i)$  les coordonnées du *i*<sup>ème</sup> voisin de v(A, x, y, z). L'algorithme

de calcul de la carte de plus proche voisin est donné dans le tableau 11.4. La carte de distance est inévitablement calculée, afin que les tests de mise à jour du plus proche voisin soient cohérents, mais seule la carte de plus proches voisins doit être conservée au final.

De plus, ce calcul et sa mémorisation peuvent avoir lieu *off-line* une unique fois pour toutes les surfaces des objets de l'atlas. Cette étape de prétraitement de l'atlas ne pénalise donc pas le temps d'exécution de notre procédure.

TAB. 11.4 – Algorithme de calcul d'une carte de plus proche voisin

- pour tous les voxels v(A, x, y, z) faire - si v(A, x, y, z) est sur la surface - alors D(x, y, z) = 0 et PPV(x, y, z) = [x, y, z]- sinon  $D(x, y, z) = +\infty$ - pour tous les voxels v(A, x, y, z) hors surface pris dans l'ordre faire - pour tout *i* dans  $Ch_{forth}$  faire - si  $D(x_i, y_i, z_i) + ch_i < D(x, y, z)$  faire -  $D(x, y, z) = D(x_i, y_i, z_i) + ch_i$ -  $PPV(x, y, z) = PPV(x_i, y_i, z_i)$ - pour tous les voxels v(A, x, y, z) hors surface pris dans l'ordre inverse faire - pour tout *i* dans  $Ch_{back}$  faire - si  $D(x_i, y_i, z_i) + ch_i < D(x, y, z)$  faire -  $D(x, y, z) = D(x_i, y_i, z_i) + ch_i$ -  $PPV(x, y, z) = D(x_i, y_i, z_i) + ch_i$ -  $PPV(x, y, z) = PPV(x_i, y_i, z_i)$ 

La carte de distance obtenue par cette méthode ne donne qu'une approximation de la distance euclidienne. En particulier, elle ne garantit pas que l'ordre des distances est respecté [VINC-91] [VERW-91]: il se peut qu'un voxel, dont la distance donnée par la carte est supérieure à celle d'un autre voxel, soit en fait, au sens de la distance euclidienne, à plus faible distance de la surface. Cela entraine que la carte de plus proche voisin est quelque peu erronée.

Néanmoins, cette erreur est très négligeable par rapport au fait que le recalage est, dans son ensemble, très approximatif.

Notons que l'algorithme ICP de recalage est utilisable avec une carte de plus proche voisin; la correspondance surfacique s'apparente après convergence à  $P_0 \Leftrightarrow Y_k$ , pour reprendre les notations de la section 9.2.3. Cependant l'ICP ne fournit qu'un recalage rigide. Nous avons donc choisi de sacrifier la rotation au profit de le transformation affine.

# 11.2.2 Régularisation

Le correspondant dans l'atlas d'un voxel surfacique de l'objet dans l'image est obtenu par la conjugaison d'une transformation rigide et de la carte de plus proche voisin à la surface dans l'atlas de ce même objet.

La topologie des surfaces n'est pas structurée ; les surfaces sont considérées uniquement comme des ensembles de voxels. Aussi, la régularité de la correspondance obtenue est affectée par des discontinuités liées à la carte de plus proche voisin ; celles-ci, que nous avons observées empiriquement, sont d'autant plus rares qu'elles sont fortes.

Afin de les atténuer, nous proposons une procédure de régularisation des correspondances surfaciques, dont l'algorithme est donné par le tableau 11.5. Cette procédure modifie itérativement, et de façon parallèle, les correspondances surfaciques ; à chaque itération, le correspondant d'un voxel est remplacé par le plus proche voisin (sur la surface de l'objet dans l'atlas) du correspondant moyen de ses voisins (au sein de la surface de l'objet dans l'image).

– itérer		
- pour tous les voxels $v(I, x, y, z)$ surfaciques faire		
- count = 0		
$- \ a = (0, 0, 0)$		
- pour tous les voxels $v(I, x_i, y_i, z_i)$ surfaciques et voisins stricts de $v(I, x, y, z)$ faire		
- count = count + 1		
$-a=a+f_v(v(I,x_i,y_i,z_i))$		
$-f_v'(v(I,x,y,z))=a/count$		
- pour tous les voxels $v(I, x, y, z)$ surfaciques faire		
$- x' = X(f'_v(v(I, x, y, z)))$		
$- y' = Y(f'_v(v(I,x,y,z))))$		
$-  z' = Z( f_v'(v(I,x,y,z)))$		
$- f_v(v(I, x, y, z)) = PPV(x', y', z')$		

TAB. 11.5 – Algorithme de regularisation surfacique

Pour que la régularisation soit correcte, la surface de l'objet doit être de courbure assez faible; aussi, l'objet ne doit pas être trop petit, et la surface ne doit pas être irrégulière. Cette régularisation est bien adaptée à la surface cérébrale, mais l'est beaucoup moins pour celle des structures internes; nous nous sommes limités à régulariser seulement cette première.

Le nombre d'itérations nécessaire à une régularisation correcte dépend du nombre de voxels de la surface. Empiriquement, nous avons choisi 3 itérations, ce qui améliore légèrement la correspondance.

# **11.3** Extension au volume de la mise en correspondance

Une fois les surfaces de l'objet dans l'image et dans l'atlas mises en correspondance, l'étape suivante consiste à inférer une mise en correspondance volumique à partir de l'information surfacique.

# **11.3.1** Champ de laplacien nul

Afin de réaliser cette inférence, nous choisissons un modèle que doit suivre le champ de correspondance  $f_E$ ; nous supposons que son laplacien vectoriel est nul:

$$\triangle f_E = \vec{0} ,$$

soit:

$$\begin{cases} \Delta X(f_E) = 0\\ \Delta Y(f_E) = 0\\ \Delta Z(f_E) = 0. \end{cases}$$
(11.6)

Remarquons dès à présent que le champ de déformation :

$$f_E(p(I)) = f_E(p(I)) \Leftrightarrow p(I)$$

satisfait par équivalence :

$$\triangle . \vec{f_E} = \vec{0} \, .$$

Une famille de déformations qui vérifient cette hypothèse s'exprime par :

$$\begin{array}{l} \left( \vec{f_E}( \, p(I,x,y,z) \, ) \, ) \, = \, c_0^X + c_x^X x + c_y^X y + c_z^X z + c_{xy}^X x y + c_{xz}^X x z + c_{yz}^X y z + c_{xyz}^X x y z \\ \left. Y( \, \vec{f_E}( \, p(I,x,y,z) \, ) \, ) \, = \, c_0^Y + c_x^Y x + c_y^Y y + c_z^Y z + c_{xy}^Y x y + c_{yz}^Y x z + c_{yz}^Y y z + c_{xyz}^Y x y z \\ \left. Z( \, \vec{f_E}( \, p(I,x,y,z) \, ) \, ) \, = \, c_0^Z + c_x^Z x + c_y^Z y + c_z^Z z + c_{xy}^Z x y + c_{xz}^Z x z + c_{yz}^Z y z + c_{xyz}^Z x y z \, , \end{array} \right)$$

où les *c* sont des coefficients constants de valeurs quelconques. Cette famille comprend en particulier les transformations trilinéaires, et donc les transformations affines (dont les translations), mais aussi les rotations.

Cependant, l'hypothèse est beaucoup plus large, et tolère un très grand nombre de déformations, tout en imposant une régularité de la variation spatiale du champ.

# **11.3.2** Extension du champ et conditions surfaciques

A l'issue du recalage nous connaissons les valeurs du champ de correspondance sur des surfaces, nous souhaitons maintenant étendre cette connaissance à l'ensemble du volume, de telle façon que l'équation (11.6) soit vérifiée.

Pour l'objet qui vient d'être segmenté, que nous notons  $O_{nouveau}$ , le champ doit être calculé dans son intérieur. Comme ce nouvel objet est connexe et sans trou, il ne possède pas de surface interne, et il n'y a donc aucune différence entre son intérieur large et son intérieur (strict).

Un nouvel objet s'inscrit généralement dans l'intérieur d'un objet précédemment segmenté, que nous notons  $O_{englobant}$ ; aussi, ce dernier doit être modifié. Une surface interne apparaît s'il ne possédait pas encore d'objet inclus, ou dans le cas contraire, sa surface interne est augmentée par un nouvel élément surfacique; l'ensemble de voxels qui constituent son intérieur se réduit. Le champ de déformation, quant à lui, doit être mis à jour dans son nouvel intérieur large.

Notons  $O_{i^{\text{ème}}englobé}$ , le i<sup>ème</sup> objet inclus spatialement dans  $O_{englobant}$ , et reconnu lors d'une étape antérieure. *Nota bene* : nous considérons donc que ce n'est qu'à l'issue de cette dernière sous-étape, et donc de cette étape de reconnaissance, que le nouvel objet fera véritablement partie des objets englobés dans l'objet englobant.

La prise en compte d'un nouvel objet conduit au calcul du champ de correspondance :

- dans  $int(O_{nouveau})$ , et la seule surface qui influe sur le champ est  $surf(O_{nouveau})$ ,

- dans  $intlar(O_{englobant})$ , et les surfaces qui influent sur le champ sont  $surfext(O_{englobant})$ ,  $surf(O_{nouveau})$ , et les  $surfext(O_{i^{eme}englobe})$ .

C'est le cas, par exemple, de l'intérieur du cerveau lorsque le ventricule latéral gauche vient d'être segmenté (figure 11.2); le calcul (ou actualisation) des valeurs du champ de correspondance concerne :

- $-int(O_{VTLg}) = intlar(O_{VTLg})$  pour le nouvel objet, et la contrainte surfacique est  $surf(O_{VTLg}) = surfext(O_{VTLg}),$
- $intlar(O_{ENC})$  pour l'objet englobant déjà présent, et les contraintes surfaciques sont  $surfext(O_{ENC})$  et  $surfext(O_{VTLg})$  ( $O_{ENC}$  n'avait pas encore d'objets englobés).

Les informations connues, ou conditions aux limites du modèle, sont les valeurs de la fonction de correspondance sur les surfaces externes de l'objet nouveau et sur les objets englobés, et les informations inconnues sont les valeurs de la fonction de correspondance sur les intérieurs larges de l'objet nouveau et de son objet englobant.

Supposer que le modèle est vérifié au sein de régions hermétiques signifie qu'en fait les déformations peuvent avoir des expressions différentes d'une région à l'autre.

Le problème d'extension du champ de correspondance est, à chaque itération de notre procédure (à la prise en compte de tout nouvel objet), un problème régional.

Notons  $R^{int}$  l'ensemble des voxels tels que :

$$R^{int} = intlar(O_{englobant}) \cup intlar(O_{nouveau})$$

D'après les notation du tableau 11.2, nous pouvons écrire que l'extension du champ de correspondance à une étape donnée revient à calculer  $f_{R^{int}}$ . Notons  $R^{surf}$  l'ensemble des voxels tels que :

 $R^{surf} = surfext(O_{englobant}) \cup surfext(O_{nouveau}) \cup (\cup_i surfext(O_{i^{eme}englobe})).$ 

Cet ensemble constitue les limites de l'extension du champ de correspondance ; nous avons :

$$R^{int} \cap R^{surf} = \emptyset \,.$$

Notons R la réunion :

$$R = R^{int} \cup R^{surf} .$$

Soit la matrice  $F_V$  représentant le champ de correspondance :

$$F_V[i,j,k] = f_V(v(I,i,j,k)) .$$

Un élément de cette matrice, repéré par ces indices [i, j, k], est un vecteur de l'espace E(A):

$$F_{V}[i, j, k] = \begin{pmatrix} X(f_{V}(v(I, i, j, k))) \\ Y(f_{V}(v(I, i, j, k))) \\ Z(f_{V}(v(I, i, j, k))) \end{pmatrix}.$$

Nous appelons R-élément de  $F_V$  un élément d'indices (i, j, k) de cette matrice tel que  $v(I, i, j, k) \in R$ ; l'ensemble des valeurs de correspondance des R-éléments est noté  $F_R \in F_V$ . De même, nous définissons les  $R^{int}$ -éléments et les  $R^{surf}$ -éléments, ainsi que les ensembles associés,  $F_{R^{int}} \in F_R$  dont nous recherchons les valeurs, et  $F_{R^{surf}} \in F_R$  dont les valeurs connues sont des conditions aux limites.

# **11.3.3** Algorithme d'extension du champ de correspondance

Une technique numérique classique de résolution d'un champ de laplacien nul, connaissant les conditions aux limites, consiste à remplacer (de façon parallèle) toute valeur non-limite par la moyenne des valeurs voisines, et d'itérer ces remplacements jusqu'à convergence. Nous pouvons donc appliquer cette technique au champ des vecteurs de correspondance  $f_{E_m}$ .

La moyenne des vecteurs voisins du point  $(I, x_m, y_m, z_m)$ , que nous notons  $\overline{f_{E_m}}(I, x_m, y_m, z_m)$ , peut s'exprimer à l'aide d'une discrétisation de pas  $d_m$  dans  $E_m(I)$ :

$$\overline{f_{E_m}}(I, x_m, y_m, z_m) = \left(\begin{array}{cc} f_{E_m}(I, x_m + d_m, y_m, z_m) + f_{E_m}(I, x_m \Leftrightarrow d_m, y_m, z_m) \\ + f_{E_m}(I, x_m, y_m + d_m, z_m)) + f_{E_m}(I, x_m, y_m \Leftrightarrow d_m, z_m) \\ + f_{E_m}(I, x_m, y_m, z_m + d_m) + f_{E_m}(I, x_m, y_m, z_m \Leftrightarrow d_m) \end{array}\right) / 6.$$
(11.7)

Si l'image I était isotrope, nous aurions dans E(I) (avec pour coordonnées entières les indices des voxels):

$$\overline{f_V}(I, i, j, k) = \begin{pmatrix} f_V(I, i+1, j, k) + f_V(I, i \Leftrightarrow 1, j, k) \\ + f_V(I, i, j+1, k) + f_V(I, i, j \Leftrightarrow 1, k) \\ + f_V(I, i, j, k+1) + f_V(I, i, j, k \Leftrightarrow 1) \end{pmatrix} / 6.$$

Dans le cas d'une image I anisotropre, nous pouvons modifier l'équation (11.7) afin de donner plus de poids, dans la moyenne, aux termes plus proches du point ( $I, x_m, y_m, z_m$ ); elle devient:

$$\overline{f_{E_m}}(I, x_m, y_m, z_m) = \left( \frac{f_{E_m}(I, x_m + d_x(I), y_m, z_m) + f_{E_m}(I, x_m \Leftrightarrow d_x(I), y_m, z_m)}{d_x(I)} + \frac{f_{E_m}(I, x_m, y_m + d_y(I), z_m)) + f_{E_m}(I, x_m, y_m \Leftrightarrow d_y(I), z_m)}{d_y(I)} + \frac{f_{E_m}(I, x_m, y_m, z_m + d_z(I)) + f_{E_m}(I, x_m, y_m, z_m \Leftrightarrow d_z(I))}{d_z(I)} \right) / \alpha,$$

où  $\alpha$  est le terme normalisateur :

$$\alpha = 2\left(\frac{1}{d_x(I)} + \frac{1}{d_y(I)} + \frac{1}{d_z(I)}\right) \,.$$

Nous allons donc appliquer itérativement ce remplacement sur tous les vecteurs de correspondance de  $R^{int}$ ; d'un point de vue matriciel, nous pouvons écrire :

Cette écriture est correcte car tout 6-voisin d'un voxel de  $R^{int}$  appartient obligatoirement soit à  $R^{int}$  soit à  $R^{surf}$ , donc à R. Enfin, notons que dans le cas où I et A ont même résolution, et où A est une segmentation de I, le coefficent  $\alpha$  vaut 1, la fonction de correspondance est l'identité:

$$F_R[i,j,k] = \begin{pmatrix} i \\ j \\ k \end{pmatrix} \quad \forall \ i,j,k ,$$

et au final  $\overline{F_{R^{int}}}[i, j, k] = F_{R^{int}}[i, j, k].$ 

Les liste des opérateurs qui apparaissant dans les algorithmes que nous décrivons est donnée par le tableau 11.7 ; aux trois premiers opérateurs, nous pouvons rajouter un modifieur : pour S ensemble d'éléments de matrice, le symbole  $op_{IS}$  signifie que l'évaluation d'un opérateur op est restreinte à S.

$$\begin{aligned} \overline{F_{R^{int}}}[i,j,k] &= \left( \frac{F_R[i+1,j,k] + F_R[i \Leftrightarrow 1,j,k]}{d_x(I)} \\ &+ \frac{F_R[i,j+1,k] + F_R[i,j \Leftrightarrow 1,k]}{d_y(I)} \\ &+ \frac{F_R[i,j,k+1] + F_R[i,j,k \Leftrightarrow 1]}{d_z(I)} \right) / \alpha \,. \end{aligned}$$

TAB. 11.6 – Remplacement d'une valeur de correspondance

TAB. 11.7 – Liste d'opérateurs algorithmiques

opérateur	signification
≡	égalité
≢	différence
=	affectation
$\leftarrow$	référencement

La technique numérique de résolution s'exprime alors par l'algorithme du tableau 11.8, où  $F_{memo}$  est une matrice de travail de même taille que  $F_V$ .

Cet algorithme s'interprète facilement. Une itération consiste à remplacer, de façon parallèle, la valeur de chaque  $R^{int}$ -élément par la moyenne des valeurs prises sur le voisinage de cet élément, et cette passe est répétée jusqu'à convergence. Au final, la continuité des valeurs des  $R^{int}$ -éléments est assurée, y compris à proximité des  $R^{surf}$ -éléments ; la fonction de correspondance vérifie alors la relation (11.6).

Cet algorithme itératif est malheureusement coûteux en temps de calcul.

## **11.3.4** Modifications de l'algorithme

Afin d'accélérer cet algorithme, nous proposons et commentons ici plusieurs modifications.

En premier lieu, la copie de  $F_{memo}$  dans  $F_V$  à chaque passe est pénalisante; elle peut être évitée grâce à l'emploi supplémentaire de références ( $F_{avant}$ ,  $F_{apres}$  et  $F_{cana}$ ) à des matrices du type de  $F_V$ . L'algorithme modifié s'écrit :

- $-F_{avant} \leftarrow F_V$
- $F_{memo} =_{/R^{surf}} F_V$
- $F_{a pres} \leftarrow F_{memo}$
- répéter la passe

$$-fin = faux$$
$$-F_{apres} = -R^{int} \overline{F_{avant}}$$
TAB. 11.8 – Algorithme de résolution de  $\triangle F_R = \vec{0}$ 

-  $F_{memo} =_{/R} F_V$ - répéter la passe - fin = faux-  $F_{memo} =_{/R^{int}} \overline{F_{R^{int}}}$ -  $\operatorname{si} F_{memo} \equiv_{/R^{int}} F_V$ -  $\operatorname{alors} fin = vrai$ -  $\operatorname{sinon} F_V =_{/R^{int}} F_{memo}$ jusqu'à  $fin \equiv vrai$ 

$$- \operatorname{si} F_{apres} \equiv_{/R^{int}} F_{avant}$$

$$- \operatorname{alors} fin = vrai$$

$$- \operatorname{sinon}$$

$$- F_{cana} \leftarrow F_{avant}$$

$$- F_{avant} \leftarrow F_{apres}$$

$$- F_{apres} \leftarrow F_{cana}$$

jusqu'à  $fin \equiv vrai$ 

Un inconvénient de cet algorithme est de ne pas réduire le nombre d'itérations nécessaires à la convergence. En effet, chaque itération ne propage l'influence d'une condition aux limites qu'aux voxels voisins. Pour que l'intégralité des  $R^{int}$ -éléments soit touchée par l'ensemble des conditions aux limites, le nombre d'itérations doit être au moins égal à la plus grande distance entre deux  $R^{surf}$ -éléments.

Une solution consiste à dé-paralléliser l'algorithme, et à balayer alternativement les  $R^{int}$ -éléments dans un sens puis dans l'autre. Les contraintes sont donc propagées d'un voxel à l'autre à chaque affectation par la moyenne, et non plus seulement à chaque itération; de plus, avec l'alternance du sens de balayage, nous obtenons une réduction d'environ 25 % du nombre d'itérations nécessaires à la convergence. Cet algorithme est formalisé dans le tableau 11.9.

Une seconde solution consiste à ne dé-paralléliser l'algorithme qu'à moitié, en effectuant deux demi-itérations (Cf. le tableau 11.10). Alternativement, le balayage s'effectue de façon entrelacée parmi les  $R^{int}$ -éléments équivalents à un voxel sur deux ; la première demi-itération traite les voxels qui vérifient (i + j + k) pair, et la seconde ceux qui vérifient (i + j + k) impair. Cette fois-ci, l'ordre de balayage des  $R^{int}$ -éléments lors d'une demi-itération n'a aucune importance, car le calcul de la moyenne (tableau 11.6) ne fait intervenir que des valeurs qui resteront inchangées lors de cette demi-itération.

La convergence de cet algorithme est comparable à celle de l'algorithme précédent, en termes de nombre d'itérations et de résultat final ; néanmoins, sa demi-parallélisation nous le fait préférer.

TAB. 11.9 – Algorithme nº1 d'extension du champ de correspondance

- répéter la double-itération - fin = vrai  $- \text{ pour chaque } R^{int}\text{-élément } (i, j, k) \text{ pris dans l'ordre faire}$   $- \text{ si } (fin \equiv vrai \text{ et } F_{R^{int}}[i, j, k] \neq \overline{F_{R^{int}}}[i, j, k])$  - alors fin = faux  $- F_{R^{int}}[i, j, k] = \overline{F_{R^{int}}}[i, j, k]$   $- \text{ si } fin \equiv faux$  - alors - fin = vrai  $- \text{ pour chaque } R^{int}\text{-élément } (i, j, k) \neq \overline{F_{R^{int}}}[i, j, k] )$   $- \text{ alors } fin \equiv vrai \text{ et } F_{R^{int}}[i, j, k] \neq \overline{F_{R^{int}}}[i, j, k] )$   $- \text{ alors } fin \equiv vrai \text{ et } F_{R^{int}}[i, j, k] \neq \overline{F_{R^{int}}}[i, j, k] )$   $- \text{ alors } fin \equiv vrai \text{ et } F_{R^{int}}[i, j, k] \neq \overline{F_{R^{int}}}[i, j, k] )$  - alors fin = faux  $- F_{R^{int}}[i, j, k] = \overline{F_{R^{int}}}[i, j, k]$ 

#### 11.3.5 Initialisation du champ et critère d'arrêt de l'algorithme

Enfin, pour accélérer la convergence, nous proposons d'initialiser la valeur des  $R^{int}$ -éléments par une interpolation mono-linéaire. En effet, nous garantissons que dans toute coupe axiale chaque ligne de  $R^{int}$ -éléments est délimitée à ses deux extrémités par des  $R^{surf}$ -éléments; la valeur de ces derniers peut ainsi nous servir à initialiser les valeurs de  $F_{R^{int}}$  sur la ligne. Cette initialisation est effectuée pour l'intérieur de chaque nouvel objet segmenté. En revanche, pour un objet dont l'intérieur large a déjà subi une extension du champ de correspondance, elle n'est pas utile; nous conservons alors comme initialisation la valeur initiale des  $R^{int}$ -éléments de cet intérieur large (c'est le cas par exemple de l'intérieur large du cerveau après l'ajout du ventricule latéral gauche).

Le fait que les valeurs du champ soient flottantes est lié à notre choix d'une correspondance voxelimage à point-atlas (Cf. section 11.1.3); ce choix n'est pas arbitraire car il garantit l'obtention d'un résultat correct. Une correspondance de type voxel-image à voxel-atlas aurait été plus grossière, mais n'aurait pas gêné l'apport d'informations en provenance de l'atlas, puisqu'au final ces informations sont rendues floues. En revanche, la convergence de l'extension du champ de correspondance n'aurait été que partielle. Prenons un exemple en dimension 1 sur une ligne pour illustrer notre propos. Soit une ligne de 100  $R^{int}$ -éléments initialisés à 0 et délimités à chaque extrémité par des  $R^{surf}$ -éléments de valeurs respectives +10 et -10. Après convergence, l'algorithme itératif donne pour F les valeurs { 10 9 8 7 6 5 4 3 2 1 0 .. 0 -1 -2 -3 -4 -5 -6 -7 -8 -9 -10 }, toute valeur étant bien la moyenne de la valeur de ses voisines. Le résultat final, au lieu d'être une droite, est une ligne brisée ; la propagation est limitée par la précision du calcul numérique.

Le résultat de l'extension du champ de correspondance est donc dépendant de la précision du calcul numérique. Nous ne souhaitons pas obtenir un résultat exact, mais seulement une bonne ap-

TAB. 11.10 – Algorithme n°2 d'extension du champ de correspondance

répéter l'itération -fin = vrai- pour chaque  $R^{int}$ -élément tel que (i + j + k) est pair faire -si ( $fin\equiv vrai$  et  $F_{R^{int}}[i,j,k]\not\equiv \overline{F_{R^{int}}}[i,j,k]$  ) - alors fin = faux $-F_{R^{int}}[i,j,k] = \overline{F_{R^{int}}}[i,j,k]$  $- si fin \equiv faux$ – alors -fin = vrai- pour chaque  $R^{int}$ -élément tel que (i + j + k) est impair faire  $-\operatorname{si}(fin \equiv vrai \text{ et } F_{Rint}[i, j, k] \neq \overline{F_{Rint}}[i, j, k])$  $- \operatorname{alors} fin = faux$  $-F_{B^{int}}[i,j,k] = \overline{F_{B^{int}}}[i,j,k]$ jusqu'à  $fin \equiv vrai$ 

proximation. Le test d'arrêt du calcul en flottant de l'algorithme décrit dans le tableau 11.9, soit  $fin \equiv vrai$  et  $F_{R^{int}}[i, j, k] \not\equiv \overline{F_{R^{int}}}[i, j, k]$ , est donc remplacé par  $fin \equiv vrai$  et  $F_{R^{int}}[i, j, k] \not\cong \overline{F_{R^{int}}}[i, j, k]$ , où  $\not\cong$  signifie « assez différent »; en pratique nous évaluerons;

$$|F[i, j, k] \Leftrightarrow \overline{F}[i, j, k]| < \epsilon.$$

Si  $\epsilon \equiv 1$ , la précision du champ de correspondance serait la même que si les valeurs du champ étaient entières ; en conséquence,  $\epsilon$  doit être très inférieur à 1.

Déterminer une valeur tolérable de précision dépend de trois facteurs :

- la distance maximale entre deux R<sup>surf</sup>-éléments qui influent sur l'intérieur large dans lequel nous calculons les valeurs de correspondance,
- l'écart maximal entre les valeurs de correspondance de ces mêmes  $R^{surf}$ -éléments,
- l'initialisation de la valeur des  $R^{int}$ -éléments.

Les deux premiers facteurs sont intrinsèques aux données. Les valeurs extrêmes de ces dernières sont approximativement connues : la taille des images anatomiques classiques par résonance magnétique n'excède pas 300 voxels de côté, ce qui limite la distance entre  $R^{surf}$ -éléments, et conséquemment, la borne supérieure de l'écart entre valeurs de correspondance, qui reste généralement en-deça des 50 voxels.

Le dernier facteur en revanche est extrinsèque aux données. C'est à nous d'initialiser correctement le champ de correspondance pour les  $R^{int}$ -éléments. Si l'initialisation est proche du résultat attendu alors nous pourrons nous permettre d'arrêter rapidement la convergence ; si au contraire elle est trop approximative, alors la convergence doit être plus poussée. Les figures 11.4 et 11.5 illustrent les correspondances obtenues pour différentes valeurs de  $\epsilon$ , pour la première figure si l'initialisation est passable, et pour la seconde si l'initialisation est correcte. A  $\epsilon$  comparable, le résultat est naturellement meilleur dans le second cas. En revanche, le tableau 11.11 montre que si la précision augmente (lorsque  $\epsilon$  tend vers 0), le gain en nombre d'itérations diminue.

Cette dernière constatation, empirique, nous laisse à penser :

- que la procédure itérative a une convergence sans problème vers la solution recherchée,
- et que l'initialisation n'a pas d'importance dans le cas d'une obtention précise du champ de correspondance.

ε	mauvaise initialisation	bonne initialisation	gain (%)
	figure 11.4	figure 11.5	
0,1	48	37	23
0,01	184	145	21
0,001	736	700	5
0,0001	3117	3019	3

TAB. 11.11 – Nombre d'itérations nécessaires à la convergence

Enfin, remarquons que l'algorithme itératif ne prend en compte aucune contrainte topologique. Il se peut alors que certains voxels d'un objet dans *I*, proches de la surface de l'objet ou sur sa surface, aient pour correspondants dans *A*, des voxels extérieurs à l'objet équivalent. Ces voxels ne répondent donc pas à la seconde propriété attendue, donnée en section 11.1.4 : les voxels de l'intérieur large d'un objet dans l'image à traiter ont pour correspondance des voxels de l'objet équivalent dans l'atlas.

Afin de forcer cette propriété à l'issue de la convergence, nous réattribuons à chaque voxel de I, dont le correspondant est erroné, un nouveau correspondant; en l'occurrence, le plus proche voisin du correspondant erroné, sur la surface de référence dans A, de l'objet auquel il doit appartenir. La tactique, qui consiste à effectuer une réattribution, dès qu'un correspondant erroné se présente au cours des itérations, perturbe la convergence.

Le champ de correspondance étant modifié par ces réattributions, nous pourrions recommencer la procédure itérative afin de régulariser de nouveau le champ. Les tests empiriques que nous avons menés montrent que le nombre d'itérations, nécessaires à cette deuxième convergence, est très inférieur au nombre d'itérations de la première. De plus, le nombre de correspondants erronés à l'issue de la deuxième convergence est lui aussi inférieur à celui de la première. Ainsi, nous pourrions répérer les phases de convergence et de réattribution, jusqu'à obtenir une situation de stabilité pour le champ de correspondance.

En pratique, nous ne mettons pas ce raffinement en œuvre pour plusieurs raisons : les correspondants erronés sont en nombre réduit (de l'ordre de 1 % du volume), les modifications qu'entraîne ce raffinement sur le champ sont mineures et restent très locales, et l'estimation du champ obtenu sans ce raffinement nous est amplement suffisante.

### 11.4 Conclusion

Ce chapitre propose une méthode de calcul du champ de déformation entre une image et un atlas, qui s'intègre dans la procédure générale de reconnaissance présentée dans le chapitre 10. La



FIG. 11.4 – Convergence du champ après une initialisation passable

Chaque image de cette figure représente, dans l'espace de l'atlas, une même coupe axiale obtenue après convergence du champ de correspondance, par extension de la déformation surfacique du cerveau ; l'acquisition I qui est mise en correspondance avec l'atlas est  $xavT_1$ , et l'initialisation du champ à l'intérieur du cerveau est volontairement passable. Chaque image montre l'ensemble des correspondants des voxels de I avec leurs valeurs d'origine dans I; elle illustre donc la déformation directe de I vers A. La « grille » blanche qui apparaît sur chaque image traduit la déformation. La présence de cette grille est due à la conjonction de deux faits : tout correspondant d'un voxel de I est arrondi au voxel de A le plus proche (les coordonnées d'un correspondant étant flottante dans l'espace d'indiçage de A), et comme le nombre de voxels du cerveau dans I est inférieur à celui du cerveau dans A, certains voxels de l'espace de l'atlas n'ont pas d'antécédent par la déformation voxel à voxel. Ce phénomène n'apparaît pas dans l'application de notre procédure car, pour transférer des informations de l'atlas vers l'image, nous manipulons en fait la correspondance inverse.



FIG. 11.5 – Convergence du champ après une initialisation correcte

Cette figure fait le pendant de la figure 11.4; la seule différence provient d'une meilleure initialisation du champ de correspondance à l'intérieur du cerveau, avant l'exécution de la procédure itérative de calcul de ce champ. *Nota bene* : les formes blanches, qui apparaissent dans les deux images du bas de ces deux figures, à proximité des ventricules, témoignent de la forme de la grille dans l'axe perpendiculaire aux coupes axiales ; en effet, comme tous les traitements illustrés dans ce manuscrit, les déformations sont calculées et appliquées tridimensionnellement.

problématique est double :

- trouver la correspondance surfacique entre un objet segmenté et sa référence dans l'atlas (section 11.2),
- inférer cette correspondance sur le volume de l'image (section 11.3).

Ces deux points sont indépendants et constituent « deux boîtes noires » pour la procédure de reconnaissance.

Pour le premier point, nous nous sommes limités à une technique relativement simple de recalage, s'appuyant sur la matrice des moments d'ordre deux et sur une projection au plus proche voisin. Ce recalage « élastique » mériterait d'être raffiné ; cependant, en l'état, il s'avère suffisant.

En revanche, pour le second point, nous proposons une méthode originale d'extension d'un champ de déformation à partir des déformations surfaciques :

- le modèle choisi pour le champ de déformations, dans chaque région délimitée par des surfaces extérieures d'objets, est que son laplacien vectoriel est nul (section 11.3.1),
- la technique pour inférer en tout point du volume un vecteur de déformation, connaissant les valeurs des vecteurs de déformation sur des surfaces voisines, est une optimisation globale (Cf. tableaux 11.9 et 11.10),
- ce calcul est restreint, à chaque itération, à une région d'intérêt (section 11.3.2),
- et enfin, le calcul ne porte en fait pas sur des déformations, mais sur des correspondances (section 11.3.3).

Le choix du modèle est motivé par sa simplicité, qui est en accord avec notre objectif de n'obtenir qu'une approximation des déformations, par la régularité qu'il impose aux déformations, et par la facilité d'obtention d'une solution.

La modélisation aboutit à un problème d'optimisation globale, où chaque vecteur surfacique, condition aux limites, influe sur l'ensemble des vecteurs extra-surfaciques.

Nous nous éloignons donc de l'approche locale utilisée dans [THOM-96b], où seuls les vecteurs connus des régions surfaciques les plus proches d'un point donné participent au calcul du vecteur en ce point. En revanche, notre approche ressemble à celle de *Moshfeghi* [MOSH-91] [MOSH-94], où le vecteur en un point vaut la somme de tous les vecteurs connus, pondérée par leurs distances respectives au point en question.

Contrairement à cette dernière approche globale, l'algorithme itératif d'inférence du champ que nous utilisons peut facilement étendu par un procédé de calcul multi-échelles. Le gain en temps de calcul peut donc être réduit, tout en augmentant la précision des résultats. Nous n'avons pas mis en œuvre cette adaptation, qui demeure une perspective de notre travail.

Les contraintes topologiques imposées à la correspondance (surface donne surface, intérieur donne objet), permettent, à chaque étape, de restreindre le calcul du champ de correspondance à une région d'intérêt, délimitée par des surfaces externes d'objets anatomiques. Cette restriction, qui limite le temps de calcul, traduit une propriété très importante du modèle. Si ce dernier est unique, il y a en fait autant de déformations différentes qu'il y a de régions, donc d'objets; les surfaces empêchent tout effet de bord de la procédure d'extension du champ.

Enfin, le fait que le calcul porte sur des correspondances, plutôt que sur des déformations, donne un champ directement appliquable aux voxels de l'image à traiter. S'appuyant sur un modèle sousjacent, notre méthode se présente comme un traitement d'images numériques à part entière.

# Chapitre 12

# Segmentation à partir de classifications contraintes par fusion d'informations spatiales

Les différentes sous-étapes de notre procédure de reconnaissance sont énumérées en section 10.1.2 (page 218). Les deux dernières sous-étapes, qui gèrent le champ de déformation progressive et qui constituent à elles seules une originalité, ont été présentées dans le chapitre 11.

Le présent chapitre décrit les autres sous-étapes, dont le but essentiel est d'introduire des contraintes spatiales utilisées ensuite dans les classifications et la segmentation. Nous justifions le choix des différentes techniques que ces sous-étapes font intervenir, et nous détaillons ces techniques :

- en section 12.1, nous exprimons dans l'image, à l'aide du champ de correspondance, l'objet de référence porté par l'atlas,
- en section 12.2, nous expliquons comment traduire en ensembles flous, représentés par des images, différents types d'informations symboliques,
- en section 12.3, nous obtenons une région d'intérêt par dilatation floue,
- en section 12.4, nous voyons comment mener des classifications dans cette région d'intérêt floue,
- en section 12.5, nous réalisons la fusion d'informations, la sélection d'une région issue des classifications, et enfin la segmentation.

### 12.1 Expression dans l'image de l'objet de référence

La première sous-étape consiste à exprimer, dans l'espace de l'image, la forme de l'objet telle qu'elle est connue dans l'atlas. Cela est réalisable grâce au champ de correspondance.

Dans l'atlas que nous utilisons, tout objet O de référence est représenté de façon binaire (si l'atlas était moyen ou probabiliste, cela ne serait pas le cas). L'information concernant cet objet est donc, au voxel v(A) de l'atlas :

$$\mathcal{A}(v(A)) = \begin{cases} 1 & \text{si } v(A) \text{ appartient à l'objet} \\ 0 & \text{sinon} \end{cases}$$

Pour obtenir l'information qui correspond à un voxel v(I, i, j, k) de l'image I à traiter, nous connaissons son correspondant dans l'atlas: il s'agit du vecteur  $F_V[i, j, k]$ , dont les coordonnées sont exprimées en virgule flottante, et sont liées au système d'indices de A. En formant :

$$p(A, x, y, z), \begin{cases} x = X(F_V[i, j, k]) \\ y = Y(F_V[i, j, k]) \\ z = Z(F_V[i, j, k]), \end{cases}$$

nous sommes placés dans l'alternative soulevée en section 11.1.3 : l'information  $\mathcal{I}(i, j, k)$  peut être soit celle du plus proche voxel voisin de p, formule (11.4), soit une information interpolée à partir de celles des huit voxels dont les centres entourent p, formule (11.5).

Du fait de l'information binaire A de la présence de l'objet, le premier cas nous donne dans I un objet binaire (image (a) figure 12.1), tandis que le second nous donne un objet flou sur sa périphérie, ce flou traduisant l'imprécision de la localisation de sa surface (image (b) figure 12.1).



FIG. 12.1 – Transformation inverse d'un objet binaire par le champ de correspondance

Ces images montrent le résultat de la transformation inverse par le champ de correspondance d'un objet binaire de l'atlas; l'image (a) utilise une correspondance au plus proche voisin, et l'image (b), une correspondance avec interpolation trilinéaire.

Une correspondance au plus proche voisin nous suffit car l'information exprimée dans l'image I n'a pas besoin d'être précise; cette information est une approximation que nous n'utilisons pas en l'état. En l'occurrence, elle est par la suite (section 12.3) dilatée de façon floue pour définir une région d'intérêt. Notons  $\mathcal{I}_{atlas}$ , l'image-information tirée de l'atlas.

### 12.2 Traduction en images des informations symboliques

Chaque information symbolique décrivant l'objet recherché en fonction de connaissances *a priori* est traduite sous la forme d'une image. Ces informations concernent aussi bien des relations spatiales (ensemblistes, directionnelles, de distances) que des considérations radiométriques.

### 12.2.1 Contrainte spatiale

En section 11.1.4, nous avons affirmé que tout ajout d'objet dans l'image résultat ne peut pas empiéter sur la surface externe d'un objet déjà présent. Cette contrainte est essentielle puisqu'elle garantit que tout objet conserve, tout au long de la procédure de reconnaissance, la surface externe issue de sa segmentation. Ainsi, la segmentation d'un nouvel objet ne peut pas remettre en cause celles des objets déjà obtenus ; de plus, les surfaces externes sur lesquelles s'appuie l'extension progressive du champ de correspondance ont un caractère immuable d'une étape de la reconnaissance à l'autre.

Connaissant l'objet englobant dans lequel un nouvel objet est recherché, nous pouvons contraindre la segmentation du nouvel objet dans l'intérieur large de son objet englobant  $O_{englobant}$  (Cf. section 11.3.2). La région de recherche de l'objet s'exprime par l'information binaire  $\mathcal{I}_{cont}$  telle que :

$$\mathcal{I}_{cont}(v(I)) = \begin{cases} 1 & \text{si } v(I) \text{ appartient à } intlar(O_{englobant}) \\ 0 & \text{sinon}. \end{cases}$$

Toutes les informations que nous manipulons peuvent être conditionnées par cette contrainte (une illustration d'une information de contrainte est donnée plus loin page 271, par la première image de la figure 12.8).

#### **12.2.2** Direction spatiale

Comme nous l'avons vu dans la partie I (sections 1.6.2 et 1.7), un objet peut être décrit grâce à des relations spatiales directionnelles, qui font intervenir un ou plusieurs autres objets.

A une étape donnée de la procédure, un certain nombre d'objets ont déjà été segmentés et reconnus; ils peuvent donc nous servir à mettre en œuvre des informations directionnelles permettant de repérer l'objet recherché. Si, pour notre problématique, les objets connus ne sont pas flous, en revanche l'information de direction est imprécise, donc floue.

Une information directionnelle relative, dans le cerveau, s'exprime avec des variables linguistiques telles que : « inférieur à l'objet untel ». L'ensemble des 6 variables linguistiques « primaires » (Cf. section 1.1.1) est :

- inférieur, supérieur,
- antérieur, postérieur,
- médial, latéral.

Cet ensemble peut être étendu par la composition de deux variables primaires non antagonistes (appartenant à deux lignes différentes de l'énumération ci-dessus); sont ainsi définies 12 variables supplémentaires (par exemple antéro-inférieur). De même, la combinaison de trois variables primaires non antagonistes entre elles fournit 8 nouvelles variables (par exemple antéro-inférieur-médial). Nous retrouvons ainsi les 26 directions correspondant à un voxel et à un de ces 26-voisins. Un point important est qu'une information de direction est également relative à l'orientation du cerveau. Pour que l'information soit pertinente, l'orientation du cerveau doit donc être connue.

Pour cela, nous pouvons choisir un référentiel intrinsèque au cerveau, celui de Talairach par exemple. Si ce référentiel est connu dans l'atlas (parce que les axes du référentiel coïncident avec les directions d'échantillonnage de l'atlas par exemple), les paramètres de la mise en correspondance de l'objet cerveau entre l'atlas et l'image nous permettent alors de connaître ce référentiel dans l'image. Ainsi toute direction exprimée avec les termes linguistiques courants en anatomie peut être déterminée dans l'image.

La plupart des travaux de recherche traitent de la notion de position spatiale relative de deux objets dans une image bidimensionnelle, et pour définir cette notion, s'appuient sur la mesure des angles entre les points des deux objets [KRIS-93b] [RHEE-94] [MIYA-94] [MIYA-94b] [KELL-95] (voir [BLOC-97c] pour une revue plus complète). Les variables linguistiques utilisées sont donc exprimées dans l'espace des angles, après qu'une direction de référence a été définie dans l'image.

Notre problématique est différente. Nous voulons calculer l'image floue qui correspond à l'expression d'une variable linguistique donnée pour un objet de référence (« inférieur à l'objet untel »). Le domaine sur lequel est définie la variable linguistique est l'ensemble des voxels de l'image, et son expression dépend de l'objet de référence.

Nous présentons ici une analogie entre ces deux problématiques.

Chaque variable linguistique (à gauche, en haut, à droite, en bas), qui traduit une relation de position relative floue, prend la forme d'un ensemble flou dont le paramètre est un angle  $\theta \in [\Leftrightarrow \pi, \pi]$ . Notons pour chaque relation dir:

$$\mu_{dir}: \theta \mapsto \mu_{dir}(\theta) \quad \text{où} \quad rel \in \{gauche, haut, droite, bas\},\$$

l'ensemble flou associé.

Dans [MIYA-94] [MIYA-94b], ces ensembles flous sont définis par des fonctions en  $\cos^2 \theta$  et  $\sin^2 \theta$ ; dans [KRIS-93b] [RHEE-94] [KELL-95], ce sont des fonctions trapézoïdales. Typiquement, la valeur d'appartenance  $\mu_{droite}(\theta)$  augmente jusqu'à 1 lorsque  $\theta$  tend vers 0.

De façon classique, entre deux points de l'image a et b, un angle  $\theta(a, b) \in [\Leftrightarrow \pi, \pi]$ , formé par le segment qui relie ces points et par la direction de référence, peut être mesuré. A partir de telles mesures, la position relative de deux objets peut être évaluée ; notons O l'objet dont la position est évaluée,  $O_{ref}$  l'objet de référence dans cette évaluation, et :

$$\mu_{dir}(O_{ref}, O)$$

le degré de satisfaction de la relation dir. Trois méthodes sont proposées :

Une première solution, simple, consiste à représenter chaque objet par un point caractéristique v, par exemple son centre de masse [KRIS-93b] [KELL-95]. Un seul calcul d'angle entre les deux points caractéristiques est effectué, et le degré de satisfaction de la relation s'en déduit :

$$\mu_{dir}(O_{ref}, O) = \mu_{dir}(\theta(v_{O_{ref}}, v_O)).$$

 Dans [KRIS-93b] [KELL-95], une méthode d'agrégation prend en compte tous les points des deux objets, au lieu des seuls deux points caractéristiques. L'appartenance à la relation est calculée pour tout couple de points; toutes ces valeurs sont alors agrégées par une moyenne pondérée :

$$\mu_{dir}(O_{ref}, O) = \left[\sum_{p_{ref} \in O_{ref}} \sum_{p \in O} w_{p_{ref}, p} \ \mu_{dir}^q(\theta(p_{ref}, p))\right]^{\frac{1}{q}},$$

où  $q \ge 1$  est une constante, et où les poids  $w_{p_{ref},p}$ , dont la somme est normalisée à 1, sont appris à l'aide d'un réseau de neurones et d'un ensemble d'apprentissage.

– Dans [MIYA-94] [MIYA-94b], un ensemble flou est défini pour représenter la compatibilité entre un histogramme angulaire et la relation floue. L'histogramme angulaire H est construit à partir de l'angle entre tout couple de points des deux objets, et normalisé par l'occurrence maximum. Un ensemble de compatibilité  $\mu_{C(H,\mu_{dir})}$  est alors défini dans [0,1] en utilisant le principe d'extension :

$$\mu_{C(H,\mu_{dir})}(u) = \begin{cases} 0 & \text{si } \mu_{dir}^{-1}(u) = \emptyset\\ \sup_{\theta, u = \mu_{dir}(\theta)} H(\theta) & \text{sinon}. \end{cases}$$

Une évaluation globale de la position relative est alors donnée par le centre de masse de l'ensemble flou de compatibilité.

Dans notre problématique de description anatomique cérébrale, nous cherchons à exprimer les variables de l'ensemble :

```
{ inférieur à , supérieur à , antérieur à , postérieur à , médial à , latéral à } ,
```

ainsi que leur combinaison. Dans des images tridimensionnelles, chacune de ces variables traduit une relation dir de position relative (de direction) qui peut être déterminée par deux angles, soit un vecteur angulaire que nous notons :

$$ec{ heta_{dir}} = \left( egin{array}{c} heta_{dir}^{(XY)} \ heta_{dir} \ heta_{dir}^{(Z)} \end{array} 
ight) \,.$$

*Nota bene* : lorsque la relation fait intervenir la notion de latéralité (ou de médialité), sa direction associée dépend de l'hémisphère auquel appartient l'objet de référence ; le vecteur angulaire est sans ambiguïté une fois que la localisation de objet de référence est précisée par une des trois caractéristiques suivantes :

- $-O_{ref}$  est médial,
- $-O_{ref}$  est latéral gauche,
- $-O_{ref}$  est latéral droit.

De plus, de façon arbitraire, nous considérons qu'une direction médiale ne se limite pas au demihémisphère, mais traverse le plan inter-hémisphérique; nous n'employons donc pas une telle relation si l'objet de référence occupe les deux hémisphères. Enfin, si l'objet de référence est médial, et si la relation fait intervenir la latéralité sans préciser ni « gauche » ni « droite », nous fusionnons (par un opérateur max) les deux informations de latéralité.

Dans le repère de Talairach (Cf. section 9.1.2), en notant  $\vec{D}_{dir}$  le vecteur directionnel, nous pouvons définir :

- $-\theta_{dir}^{(XY)}$  dans le plan  $(O \Leftrightarrow XY)$ , par l'angle formé entre la projection sur ce plan de  $\vec{D}_{dir}$  et l'axe des X,
- et  $\theta_{dir}^{(Z)}$  dans le plan comprenant  $\vec{D}_{dir}$  et  $(O \Leftrightarrow Z)$ , par l'angle formé entre  $\vec{D}_{dir}$  et sa projection.

Prenons deux exemples. Postérieur signifie dans la direction AC-PC, soit :

$$\vec{\theta}_{\text{postérieur}} = \begin{pmatrix} \pi/2 \\ 0 \end{pmatrix};$$

médial-supérieur, si l'objet est dans l'hémisphère gauche, donne :

$$\vec{\theta}_{\text{postérieur}} = \begin{pmatrix} \pi \\ \pi/4 \end{pmatrix}$$

Ainsi, à toute relation est associé un ensemble flou  $\vec{\theta} \mapsto \mu_{dir}(\vec{\theta})$ , et classiquement  $\mu_{dir}(\vec{\theta}_{dir}) = 1$ .

Une variable linguistique, dont nous recherchons une expression, traduit une relation à laquelle nous pouvons aussi associer un ensemble flou. Ce dernier n'est pas défini sur les angles mais sur l'image. Notons  $\mathcal{I}_{dir}^{O_{ref}}$  l'ensemble flou associé à la relation dir. Notre problème est d'estimer l'ensemble des valeurs floues :

$$\mathcal{I}_{dir}^{O_{ref}}(v(I)) \quad \forall v(I) .$$

Pour cela, nous allons considérer successivement que chaque voxel de l'image est un objet. Le degré de satisfaction de la relation *dir* d'un objet voxélique et de l'objet de référence, que donne la litté-rature, n'est autre que la valeur d'appartenance du voxel à l'ensemble flou caractérisant la variable linguistique:

$$\mathcal{I}_{dir}^{O_{ref}}(v(I)) = \mu_{dir}(O_{ref}, v(I)) .$$

Les différentes méthodes que propose la littérature peuvent donc être réutilisées; pour la méthode d'agrégation par exemple, il vient :

$$\mathcal{I}_{dir}^{O_{ref}}(v(I)) = \left[\sum_{p_{ref} \in O_{ref}} w_{p_{ref},v(I)} \mu_{dir}^q(\vec{\theta}(p_{ref},v(I)))\right]^{\frac{1}{q}}.$$

A l'exception de la première méthode, elles sont coûteuses en temps de calcul, pêchent par leur manque d'informations morphologiques, ne se comportent pas toujours bien dans le cas de fortes concavités, et supposent que les relations sont explicitement modélisées par des variables linguistiques.

Pour toutes ces raisons, nous avons opté pour une approche morphologique récente [BLOC-97c] ; l'idée d'employer des techniques de morphologie mathématique pour calculer, dans l'espace de l'image, le paysage flou d'une relation de position relative a été suggérée dans [BLOC-96b] et [BLOC-96e].

Considérons l'angle :

formé par le vecteur directionnel qui nous intéresse, et par le vecteur défini entre un voxel  $p_{ref}$  de l'objet de référence  $O_{ref}$  et un voxel v(I) de l'image. Pour chaque voxel de I, nous retenons :

$$\beta_{dir}^{min}(O_{ref}, v(I)) = \begin{cases} 0 & \text{si } v(I) \in O_{ref} \\ \min_{p_{ref} \in O_{ref}} \beta_{dir}(p_{ref} v(I)) & \text{sinon}. \end{cases}$$

Le paysage flou s'en déduit suivant :

$$\mu_{dir}(O_{ref}, v(I)) = g(\beta_{dir}^{min}(O_{ref}, v(I)))$$

où g est une fonction décroissante de  $[0, \pi]$  vers [0, 1]. Une fonction linéaire simple suffit, et au final, l'information recherchée peut s'écrire :

$$\mathcal{I}_{dir}^{O_{ref}}(v(I)) = \max\left(0, 1 \Leftrightarrow \frac{2\beta_{dir}^{min}(O_{ref}, v(I))}{\pi}\right)$$

Ce résultat peut être interprété en termes de morphologie mathématique floue; un développement complet de la construction d'une morphologie mathématique sur les ensembles flous est donné dans [BLOC-95a]. En particulier, le dilaté flou  $D_e(\mu)$  d'un ensemble flou  $\mu$  par un élément structurant flou e est défini par :

$$D_e(\mu)(v(I)) = \max_{v'(I)} t(\mu(v'(I)), e(v'(I) \Leftrightarrow v(I))),$$

où t est une t-norme. L'image  $\mathcal{I}_{dir}^{O_{ref}}$  est donc égale au dilaté flou de l'image binaire qui décrit  $O_{ref}$ , par l'élément structurant e défini sur I (et de la taille de l'image) par :

$$e(v(I)) = \max\left(0, 1 \Leftrightarrow \frac{2 \arccos\left(\frac{\overline{v(I)}.\vec{\theta}_{dir}}{||\overline{v(I)}||}\right)}{\pi}\right),$$

et illustré par la figure 12.2.



FIG. 12.2 – Elément structurant flou pour une information directionnelle par dilatation

L'obtention d'une image floue traduisant une variable linguistique de relation spatiale directionnelle, ici « à droite d'un objet », est réalisée par dilation floue de l'image de cet objet. Cette figure représente l'élément structurant utilisé pour cette dilatation; il est de la taille de l'image, et sa construction ne dépend que de la direction considérée. Le code des niveaux de gris est proportionnel aux valeurs d'appartenance (le blanc correspond à la valeur 0, et le noir à la valeur 1).

Cette méthode, qui s'applique de façon très similaire si l'objet de référence est flou, présente des propriétés d'invariance par transformation géométrique, importantes pour la reconnaissance des formes, ainsi que des lois de variation en fonction de la distance entre les objets. De façon empirique, nous avons observé un bon comportement de cette méthode dans le cas d'objets de référence de forme quelconque, et en particulier lorsqu'ils possèdent des concavités. Enfin, pour limiter le coût de calcul, une méthode approximative de calcul par propagation est décrite dans [BLOC-97c].

La figure 12.3 montre l'information linguistique « dans la direction médiale par rapport au ventricule latéral droit », ce qui se doit comprendre, pour la coupe axiale représentée, par « à droite du ventricule latéral qui est à gauche ». Cette information, comme toutes celles que nous manipulons, est conditionnée par  $\mathcal{I}_{cont}$ .



FIG. 12.3 – Information directionnelle

L'information floue linguistique « dans la direction médiale par rapport au ventricule latéral droit » se traduit par une image, que nous avons ici conditionnée par le masque du cerveau. Nous avons ajouté, en blanc sur cette illustration, le ventricule latéral droit (à gauche dans l'image), et le contour du ventricule latéral gauche (à droite dans l'image).

Nous pouvons observer que la relation « le ventricule latéral gauche est, au sein du cerveau, dans la direction médiale par rapport au ventricule latéral droit » est bien satisfaite: sa localisation coïncide avec de fortes valeurs d'appartenance.

#### **12.2.3** Distance spatiale

A l'instar d'une information directionnelle, l'expression d'une information de distance s'inscrit dans un formalisme flou, car cette information est intrinsèquement imprécise ; cependant, cette expression s'appuie sur des objets non flous, issus des étapes antérieures de notre procédure.

Une information floue de distance peut se déduire très aisément d'une carte de distance. Cette dernière s'obtient de façon simple et rapide [BORG-86], tout en prenant en compte l'anisotropie de l'image (Cf. l'annexe A et l'algorithme du tableau 8.1).

L'expression en millimètres des distances permet de rendre leur utilisation systématique, soit directement si l'ensemble des images de cerveaux à traiter sont de tailles comparables, soit avec une

légère adaptation, pour pallier les différences volumétriques liées à l'âge et au sexe, et les différences morphologiques.

Deux distances distinctes peuvent nous intéresser, la distance à un objet, extérieure à cet objet, et la distance intérieure à un objet (ou distance à son complémentaire). Le second cas survient lorsque cet objet est l'objet englobant de celui que nous recherchons.

Dans les deux cas, après obtention de la carte de distance, l'information désirée se traduit en image par :

$$\mathcal{I}_{dist}(v(I)) = \mu(d(v(I))),$$

où d est la distance de la carte au voxel v(I), et  $\mu$  la fonction d'appartenance.

Suivant le type d'information exprimée (recherche d'un objet à une distance approximativement égale, inférieure, ou supérieure à D d'un autre objet, ou encore, bien à l'intérieur d'un objet), l'ensemble flou  $\mu(d)$  n'est pas le même. La figure 12.4 donne l'exemple de fonctions d'appartenance affines par morceaux ; d'autres allures de fonctions pourraient être choisies.

### 12.2.4 Radiométrie et matière

En section 2.3, nous avons montré que la modélisation par des lois gaussiennes de l'observation radiométrique des différentes structures est une bonne approximation.

Connaissant la matière constitutrice mat de l'objet recherché, et les moyenne  $\overline{r_{mat}}$  et écart-type  $\sigma_{mat}$  radiométriques de cette matière, le degré d'appartenance d'un voxel à cette matière en fonction de sa radiométrie peut se déduire de la loi de probabilité.

Pour passer à un formalisme flou, nous modélisons le degré d'appartenance d'un voxel à une matière par une forme également gaussienne :

$$\mu_{mat}(v(I)) = \exp\left[ \Leftrightarrow_{\overline{2}}^{1} \left( \frac{||r(v(I)) \Leftrightarrow \overline{r_{mat}}||^{2}}{\sigma_{mat}^{2}} \right) \right] \,,$$

où r(v(I)) et la radiométrie (ou le vecteur radiométrique) du voxel v(I). Bien que l'interprétation ne soit plus alors la même que celle d'une distribution de probabilités, ce modèle traduit bien la dépendance entre appartenance et radiométrie, et suffit ici.

L'information de la connaissance *a priori* de la matière et de sa radiométrie s'exprime alors par l'image  $\mathcal{I}_{mat}$  telle que :

$$\mathcal{I}_{mat}(v(I)) = \mu_{mat}(v(I)).$$

Une illustration d'une telle information est donnée plus loin page 271, par la dernière image de la figure 12.8.

Partant d'une segmentation initiale du cerveau, les estimations des lois radiométriques de trois matières sont connues : ce sont celles du liquide céphalo-rachidien, de la substance grise, et de la substance blanche (Cf. tableau 5.3 page 107).

Au cours des étapes de reconnaissance, ces estimations peuvent être réévaluées. Nous avons montré en section 8.3 qu'éroder un objet segmenté permet l'obtention correcte des caractéristiques radiométriques de sa matière constitutrice (car les voxels de volumes partiels sont écartés des statistiques), et que cette obtention est robuste vis-à-vis de l'imprécision de la segmentation. Nous réutilisons donc cette technique afin que les informations radiométriques soient les plus précises possibles.



FIG. 12.4 – Informations floues de distances spatiales relatives

Chaque ligne représente un ensemble flou correspondant à une information de distance spatiale ; la colonne de gauche donne l'allure de la fonction d'appartenance lorsque la distance varie, et celle de droite montre l'image résultant d'une application particulière. La première ligne correspond à l'information floue « distance égale environ à D » ; elle est illustrée par le putamen de distance à la surface cérébrale à peu près constante. La deuxième ligne correspond à « distance inférieure à environ D », ce qui est caractéristique des noyaux caudés par rapport aux ventricules latéraux (superposés en blanc). La troisième ligne correspond à « bien à l'intérieur », ce qui est le cas des ventricules latéraux dans le cerveau. Pour tous ces exemples, le contour des objets qui satisfont ces relations sont en blanc ; les valeurs d'appartenance sont représentées en niveaux de gris, de clairs pour les faibles valeurs à foncés pour les fortes.

Une réévaluation est particulièrement appréciable car, comme le montre le tableau 2.5 page 52, les objets contitués d'une même matière n'ont pas exactement les mêmes comportements radiométriques. Nous raffinons donc au cours de la procédure les informations radiométriques. En particulier, lorsqu'un objet latéral vient d'être segmenté, l'information radiométrique estimée est utilisée ultérieurement pour la segmentation de l'objet symétrique dans l'autre hémisphère.

### 12.3 Obtention d'une région d'intérêt

La troisième sous-étape d'une étape de notre procédure de reconnaissance consiste à déterminer une région d'intérêt  $\mathcal{I}_{roi}$  dans l'image I à traiter, de telle façon que cette région contienne avec une forte probabilité l'objet recherché.

Du fait de la variabilité inter-individus de chaque structure cérébrale, cette région d'intérêt doit être systématiquement surestimée. Cette surestimation doit être d'autant plus importante que la structure est intrinsèquement sujette à une forte variabilité morphologique ou de localisation, et que sa localisation dans le cerveau est diffilement repérable grâce aux objets déjà segmentés.

Ce dernier point est primordial car il est extrinsèque à l'anatomie cérébrale. Au cours de notre procédure, les objets sont reconnus successivement; à une étape donnée, les objets déjà reconnus déterminent le champ de correspondance par leur morphologie et leur localisation. Si l'objet à segmenter à cette étape est très dépendant d'un ou de plusieurs objets déjà reconnus, parce que sa morphologie ou sa position est très liée à ces objets, alors le champ de déformation est un guide précis; dans le cas contraire, le champ de déformation n'apporte pas une information très précise.

La détermination de la région d'intérêt pour un objet donné dépend donc aussi de l'ordre dans lequel les objets sont traités par notre procédure.

Afin de prendre en compte tous les cas de figure, une méthode paramétrable est nécessaire. Connaissant, dans l'image, l'information  $\mathcal{I}_{atlas}$  donnée par l'atlas et concernant l'objet recherché (section 12.1), nous pouvons en déduire par dilatation la région d'intérêt. Entre une dilatation floue et une dilatation non floue, nous avons choisi la première solution, qui traduit bien l'imprécision inhérente à la détermination de la région.

La dilatation est définie par un élément structurant flou de symétrie sphérique. Il est défini complètement par la fonction e(ra) décroissante qui associe au rayon ra positif la valeur de l'élément structurant. Il possède deux paramètres qui jouent un rôle prépondérant : le rayon  $ra_{noyau}$  de son noyau, et le rayon  $ra_{support}$  de son support; soit :

$$ra_{noyau} = \max_{ra} \{ ra, e(ra) = 1 \}$$
  
$$ra_{support} = \max_{ra} \{ ra, e(ra) > 0 \}.$$

 $ra_{noyau}$  s'interprète, de façon schématique, comme la plus grande distance que nous pouvons rencontrer entre l'objet modèle de l'atlas et ce même objet pour une anatomie « classique », tandis que  $ra_{support}$  s'interprète comme la plus grande distance, définie de façon similaire, mais pour une anatomie « anormale » (dans des cas pathologiques par exemple). Ces deux valeurs témoignent donc de la variabilité anatomique mais aussi de l'imprécision de la correspondance.

Nous avons choisi tout simplement de prendre un élément structurant dont les valeurs suivent

une fonction trapézoïdale en fonction du rayon, c'est-à-dire e tel que :

$$e(ra) = \begin{cases} 1 & \text{si } ra \leq ra_{noyau} \\ \frac{ra_{support} \Leftrightarrow ra}{ra_{support} \Leftrightarrow ra_{noyau}} & \text{si } ra_{noyau} < ra \leq ra_{support} \\ 0 & \text{si } ra > ra_{support} . \end{cases}$$

Insistons de nouveau sur le fait que les deux paramètres de cette fonction sont dépendants non seulement de l'objet recherché mais aussi de l'ensemble des objets déjà reconnus.

La mise en œuvre de la dilatation avec cet élément structurant fait appel à la même technique que celle qui nous permet d'exprimer une information de distance telle que « environ d < D », en l'occurrence, un calcul de carte de distance suivi d'une fonction de passage transformant les distances en niveaux de flou. Cet algorithme est possible ici puisque seul l'élément structurant est flou, l'ensemble à dilater  $\mathcal{I}_{atlas}$  étant binaire.

La figure 12.5 montre une région d'intérêt floue, ainsi que la superposition, sur l'image à traiter, du contour de son noyau (dilaté non flou de  $\mathcal{I}_{atlas}$  par une sphère de rayon  $ra_{noyau}$ ), et de celui de son support (dilaté non flou de  $\mathcal{I}_{atlas}$  par une sphère de rayon  $ra_{support}$ ); elle englobe effectivement l'objet recherché, en l'occurrence le ventricule latéral droit.



FIG. 12.5 – Région d'intérêt floue

La coupe de gauche montre une région d'intérêt floue destinée à contenir le ventricule latéral droit. Elle est obtenue dans l'image à partir de l'objet binaire, transformé inverse de l'objet de référence dans l'atlas (sous-étape décrite en section 12.1), une fois qu'il a été dilaté. L'élément structurant flou est à symétrie sphérique, et ses valeurs en fonction du rayon ont une allure trapézoïdale ; le rayon de son noyau est de 1 cm, et celui de son support, de 2 cm. Les contours du noyau et du support de la région floue sont superposés à l'image (à droite).

Au cours de la procédure de reconnaissance, les objets reconnus étant de plus en plus nombreux, le champ de correspondance devient de plus en plus contraint donc précis, et l'erreur de morphologie

et de localisation d'un objet de référence immergé dans l'image est de plus en plus faible. Aussi, les rayons  $ra_{noyau}$  et  $ra_{support}$  peuvent décroître.

### 12.4 Classifications dans la région d'intérêt

La quatrième sous-étape a pour but d'exhiber des classes radiométriques. Au chapitre 5, nous avons montré qu'une classification automatique par l'algorithme des k-moyennes ne donne de bons résultats que si le nombre de classes est réduit, et que si une heuristique répétitive lui est appliquée. Nous avons montré aussi que les ensembles flous obtenus par l'algorithme des c-moyennes ont une forme critiquable.

En conséquence, restreindre toute classification à une région d'intérêt englobant l'objet recherché présente l'avantage de focaliser l'attention du classifieur sur cet objet :

- les informations radiométriques extérieures à cette région, qui perturbent le classifieur (Cf. figure 4.2), sont écartées,
- le nombre de classes peut être réduit, l'objet apparaît quand même sous forme d'une classe.

Nous utilisons l'algorithme des k-moyennes, et afin de garantir qu'une classe témoigne le plus précisément possible de l'objet recherché, nous effectuons plusieurs classifications en faisant varier le nombre de classes.

La région *roi* d'intérêt, obtenue lors de la sous-étape précédente, étant floue, la classification doit en tenir compte ; pour cela, nous adaptons le calcul de l'histogramme.

Pour l'ensemble des voxels de l'image indicés par k (leurs vecteurs caractéristiques sont  $x_k \in X$ ), leur appartenance à cette région se traduit par les valeurs :

$$\forall k, \ \mu_{/roi}(x_k) \in [0, 1].$$

Le calcul de l'histogramme  $h_{/roi}$  d'une région floue est tel que pour toute radiométrie  $r_j \in X_R$ :

$$h_{/roi}(r_j) = \sum_{x_k \in X_j} \mu_{/roi}(x_k) ;$$

où  $X_j \subset X$  est l'ensemble des  $x_k = r_j$ .

Remarquons que si cette région d'intérêt n'était pas floue, nous aurions :

$$\forall k, \ \mu_{/roi}(x_k) \in \{0, 1\},\$$

et si de plus cette région d'intérêt recouvrait toute l'image, nous aurions :

$$\forall k, \ \mu_{Iroi}(x_k) = 1,$$

et nous retrouverions l'histogramme de l'image entière non floue :  $h(r_i) = card(X_i)$ .

La moyenne radiométrique sur la région floue s'écrit, comme seule la radiométrie est prise en

compte :

$$v_{i}^{(it)} = \frac{\sum_{x_{k} \in \omega_{i}^{(it)}} \mu_{/roi}(x_{k}) x_{k}}{\sum_{x_{k} \in \omega_{i}^{(it)}} \mu_{/roi}(x_{k})}$$
$$= \frac{\sum_{j=1, X_{j} \subset \omega_{i}^{(it)}} \mu_{/roi}(r_{j}) r_{j}}{\sum_{j=1, X_{j} \subset \omega_{i}^{(it)}} \mu_{/roi}(r_{j})},$$

expressions étendues des formules (5.2) et (5.4). L'expression (5.3) d'actualisation des classes reste quant à elle inchangée.

L'écart-type obtenu après convergence vers les centres  $v_i$  s'écrit quant à lui :

$$\sigma_i = \sqrt{\left( \begin{array}{c} \displaystyle \frac{\sum_{j=1, X_j \subset \omega_i} h_{/roi}(r_j) \ r_j^2}{\sum_{j=1, X_j \subset \omega_i} h_{/roi}(r_j)} \\ \displaystyle \sum_{j=1, X_j \subset \omega_i} h_{/roi}(r_j) \end{array} \right) \Leftrightarrow v_i^2 \ .$$

La figure 12.6 illustre le bénéfice que nous pouvons tirer de l'utilisation d'une région d'intérêt. Deux résultats de classification y sont représentés. La première classification est menée avec l'histogramme de l'objet cerveau, et la seconde, avec l'histogramme restreint à une région d'intérêt floue définie autour du putamen droit. Les deux classifications considèrent trois classes afin de segmenter les trois matières principales du cerveau : le liquide céphalo-rachidien et les substances grise et blanche. Comme nous le prévoyions, la seconde classification, focalisée sur son objectif, donne une bien meilleure segmentation.

Connaissant pour chaque classe, son centre et son écart-type radiométriques, l'obtention de la classe floue équivalente est naturelle ; nous formons l'information de radiométrie de la façon décrite en page 259.

Comme le nombre de classes effectives est inconnu, nous réalisons plusieurs classifications avec un nombre c de classes variable. Cela nous assure de trouver, parmi les régions résultantes des classifications, une région témoignant de la présence de l'objet recherché ; nous avons observé empiriquement qu'avec c variant de 2 à 5 nous y parvenons. Une région résultat est donc indicée d'une part par son indice  $i = 1 \dots c$  de classe, et d'autre part par le nombre de classes  $c = 2 \dots 5$  de la classification dont elle est extraite ; au final, nous obtenons 14 régions.

L'appartenance d'un voxel de l'image à la région indicée par (i, c) se traduit par un ensemble flou :

$$\mu_{(i,c)}(v(I)) = \exp\left[ \Leftrightarrow \frac{1}{2} \left( \frac{||r(v(I)) \Leftrightarrow v_{(i,c)}||^2}{\sigma_{(i,c)}^2} \right) \right] \,,$$



FIG. 12.6 – Classification par k-moyennes dans une région d'intérêt floue

Sur le schéma du haut, nous pouvons apprécier la différence entre l'histogramme des radiométries de la région cerveau (en pointillé, et avec un facteur de réduction), et celui (en trait continu) des radiométries d'une région d'intérêt floue, définie autour du putamen droit. Les classifications par l'algorithme des k-moyennes, qui s'appuie uniquement sur ces histogrammes, sont respectivement représentées en bas à gauche, et en bas à droite; trois classes sont déterminées : le liquide céphalo-rachidien, la substance grise (constituante du putamen), et la substance blanche.

et l'image floue représentant une information radiométrique de classification s'en déduit :

$$\mathcal{I}_{classe(i,c)}(v(I)) = \mu_{(i,c)}(v(I)).$$

La figure 12.7 illustre cette méthode dans une région d'intérêt floue qui entoure le noyau caudé droit, le nombre c de classes variant de 2 à 5. Parmi les informations floues  $\mathcal{I}_{classe(i,c)}$  déduites de chaque classe, la région floue obtenue pour c = 3 (deuxième colonne) et i = 3 (dernière vignette de cette colonne) s'apparente au noyau caudé.



FIG. 12.7 – Régions à sélectionner issues de classifications

La première ligne de cette figure illustre le résultat de classifications par l'algorithme des k-moyennes, calculées à partir d'une région floue entourant le noyau caudé droit (chaque résultat est représenté uniquement sur le support de cette région). Les informations floues, déduites des classes de chaque classification, sont représentées en colonne, en dessous de la première ligne. Toutes les vignettes sont extraites d'une partie d'une même coupe axiale.

### 12.5 Fusion des informations et segmentation

La dernière sous-étape précédant la mise à jour du champ de déformation consiste à fusionner les différentes informations symboliques que nous avons introduites, et à déduire de cette fusion une segmentation de l'objet recherché.

Nous présentons tout d'abord la panoplie existante d'opérateurs de fusion et de mesures de similarité, pour décrire ensuite notre logique de fusion et donner enfin une méthode générale de segmentation.

#### 12.5.1 Opérateurs de fusion

Une revue détaillée des opérateurs de fusion peut être trouvée dans [BLOC-96c]; nous n'en présentons ici que quelques uns.

Considérons deux informations  $\mathcal{I}_1$  et  $\mathcal{I}_2$ , sous forme d'ensembles flous définis sur l'image I, sur lesquelles s'applique un opérateur  $\mathcal{F}u$  de fusion (ou de combinaison):

$$(\mathcal{I}_1, \mathcal{I}_2) \iff \mathcal{I}' = \mathcal{F}u(\mathcal{I}_1, \mathcal{I}_2).$$

D'après les définitions proposées dans [DUBO-85] et [YAGE-91], et généralisées à d informations dans [BLOC-96c],  $\mathcal{F}u(\mathcal{I}_1, \mathcal{I}_2)$  peut suivre trois types de comportement :

- il est conjonctif si  $\mathcal{F}u(\mathcal{I}_1, \mathcal{I}_2) \leq \min(\mathcal{I}_1, \mathcal{I}_2)$ , ce qui correspond à un comportement sévère,
- il est disjonctif si  $\mathcal{F}u(\mathcal{I}_1, \mathcal{I}_2) \ge \max(\mathcal{I}_1, \mathcal{I}_2)$ , ce qui correspond à un comportement indulgent,
- il est un compromis si  $\min(\mathcal{I}_1, \mathcal{I}_2) < \mathcal{F}u(\mathcal{I}_1, \mathcal{I}_2) < \max(\mathcal{I}_1, \mathcal{I}_2)$ , ce qui correspond à un comportement tolérent.

Ces définitions permettent de définir trois classes d'opérateurs : à comportement constant quelles que soient les informations  $\mathcal{I}_1$  et  $\mathcal{I}_2$ , à comportement variable, et dépendant du contexte ( $\mathcal{F}u$  dépend non seulement de  $\mathcal{I}_1$  et  $\mathcal{I}_2$ , mais aussi d'une information plus globale, telle que le contexte spatial, la fiabilité des informations, etc.)

Pour notre application, nous nous limitons à des opérateurs à comportement constant. Non contextuels, ils ne font intervenir aucune information externe à  $(\mathcal{I}_1, \mathcal{I}_2)$ , et comme les informations s'expriment dans l'espace de l'image *I*, la fusion a donc lieu de façon indépendante pour tous les voxels de l'image;  $\mathcal{F}u$  est une fonction de fusion, qui s'applique à tous les points :

$$\mathcal{I}'(v(I)) = \mathcal{F}u(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I))).$$

En second lieu, ils conservent le même comportement quelles que soient les informations ( $I_1, I_2$ ).

Pour les théories des ensembles flous et des possibilités, trois familles d'opérateurs rentrent dans ces spécifications :

- les normes triangulaires (ou t-normes), qui généralisent la notion d'intersection (ET logique) aux ensembles flous, et qui sont conjonctives,
- les conormes triangulaires (ou t-conormes), qui généralisent la notion d'union (OU logique) aux ensembles flous, et qui sont disjonctives,

- les moyennes, qui sont croissantes avec chaque argument, et qui sont des compromis.

Pour les t-normes, citons :

$$\begin{aligned} \mathcal{I}'_{\text{t-norme somme bornée}}(v(I)) &= \max(0, \mathcal{I}_1(v(I)) + \mathcal{I}_2(v(I)) \Leftrightarrow 1), \\ \mathcal{I}'_{\text{t-norme produit algébrique}}(v(I)) &= \mathcal{I}_1(v(I)) \mathcal{I}_2(v(I)), \\ \mathcal{I}'_{\text{t-norme minimum}}(v(I)) &= \min(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I))), \end{aligned}$$

pour les moyennes :

$$\begin{split} \mathcal{I}'_{\text{moyenne harmonique}}(v(I)) &= \frac{2 \ \mathcal{I}_1(v(I)) \ \mathcal{I}_2(v(I))}{\mathcal{I}_1(v(I)) + \mathcal{I}_2(v(I))}, \\ \\ \mathcal{I}'_{\text{moyenne géométrique}}(v(I)) &= \sqrt{\mathcal{I}_1(v(I)) \ \mathcal{I}_2(v(I))}, \\ \\ \mathcal{I}'_{\text{moyenne arithmétique}}(v(I)) &= \frac{\mathcal{I}_1(v(I)) + \mathcal{I}_2(v(I))}{2}, \\ \\ \mathcal{I}'_{\text{moyenne quadratique}}(v(I)) &= \sqrt{\mathcal{I}_1(v(I))^2 + \mathcal{I}_2(v(I))^2}, \end{split}$$

et pour les t-conormes :

$$\begin{split} \mathcal{I}'_{\text{t-conorme maximum}}(v(I)) &= \max(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I))), \\ \mathcal{I}'_{\text{t-conorme somme algébrique}}(v(I)) &= \mathcal{I}_1(v(I)) + \mathcal{I}_2(v(I)) \Leftrightarrow \mathcal{I}_1(v(I)) \mathcal{I}_2(v(I)), \\ \mathcal{I}'_{\text{t-conorme somme bornée}}(v(I)) &= \min(1, \mathcal{I}_1(v(I)) + \mathcal{I}_2(v(I))). \end{split}$$

Comme les t-normes et les t-conormes sont associatives, nous nous sommes contentés de donner les formules de fusion de 2 informations.

#### 12.5.2 Similarité entre deux ensembles flous

La similarité entre deux ensembles flous peut être abordée avec différentes approches [ZWIC-87]; elles sont fonctionnelles, tirent parti de la théorie de l'information, des ensembles, ou de la reconnaissance des formes.

Nous avons choisi l'approche de la théorie des ensembles pour son lien direct avec la morphologie mathématique floue [BLOC-95a], et nous employons des mesures de similarité déduites de distances [BLOC-95b]. Dans cette approche, ces mesures font intervenir, directement ou non, les notions d'union et d'intersection des deux ensembles flous considérés.

Considérons les ensembles flous  $\mathcal{I}_1$  et  $\mathcal{I}_2$  définis sur l'image *I*. Une distance entre ces ensembles peut revêtir les formes suivantes :

$$\begin{split} D_1(\mathcal{I}_1, \mathcal{I}_2) &= 1 \Leftrightarrow \frac{\sum_{v(I) \in V(I)} \min(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I)))}{\sum_{v(I) \in V(I)} \max(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I)))}, \\ D_2(\mathcal{I}_1, \mathcal{I}_2) &= 1 \Leftrightarrow \max_{v(I) \in V(I)} \min(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I))), \\ D_3(\mathcal{I}_1, \mathcal{I}_2) &= \max_{v(I) \in V(I)} \max\{\min(\mathcal{I}_1(v(I)), 1 \Leftrightarrow \mathcal{I}_2(v(I))), \min(1 \Leftrightarrow \mathcal{I}_1(v(I)), \mathcal{I}_2(v(I)))\} \end{split}$$

La valeur de ces distances varie de 0 si les deux ensembles sont identiques, à 1 si le support des deux ensembles sont disjoints. Ce ne sont pas des distances spatiales (comme dans [BLOC-96a]), en ce sens qu'elles n'évaluent pas un écart de position relative des deux ensembles dans l'image, exprimé avec une unité de longueur (le millimètre par exemple). Les informations que nous allons comparer étant quelquefois superposées, une mesure de dissemblance apporte beaucoup plus de finesse, quant à la comparaison de la morphologie des deux informations, que le ferait une distance spatiale.

Deux ensembles flous  $\mathcal{I}_1$  et  $\mathcal{I}_2$  seront ressemblants si leur distance est faible; une mesure de similarité S peut se déduire aisément d'une distance D, normalisée entre 0 et 1, en posant :

$$S(\mathcal{I}_1, \mathcal{I}_2) = 1 \Leftrightarrow D(\mathcal{I}_1, \mathcal{I}_2).$$

Les distances  $D_2$  et  $D_3$  peuvent être généralisées [BLOC-95b] à l'aide de fonctions de nécessité  $\prod$  et de possibilité N [DUBO-88]. Ces fonctions expriment une adéquation floue (en anglais *fuzzy pattern matching*) entre  $\mathcal{I}_1$  et  $\mathcal{I}_2$ ; cette adéquation est respectivement optimiste pour  $\prod(\mathcal{I}_1, \mathcal{I}_2)$ , degré d'intersection de  $\mathcal{I}_1$  et  $\mathcal{I}_2$ , et pessimiste pour  $N(\mathcal{I}_1, \mathcal{I}_2)$ , degré d'inclusion de  $\mathcal{I}_2$  dans  $\mathcal{I}_1$ . Ces fonctions s'écrivent :

$$\Pi(\mathcal{I}_1, \mathcal{I}_2) = \max_{v(I) \in V(I)} t(\mathcal{I}_1(v(I)), \mathcal{I}_2(v(I))),$$
$$N(\mathcal{I}_1, \mathcal{I}_2) = \min_{v(I) \in V(I)} tco(\mathcal{I}_1(v(I)), 1 \Leftrightarrow \mathcal{I}_2(v(I))),$$

avec t une t-norme et tco une t-conorme. Les deux distances, une fois généralisées, s'écrivent :

$$D_{2g}(\mathcal{I}_1, \mathcal{I}_2) = 1 \Leftrightarrow \prod(\mathcal{I}_1, \mathcal{I}_2), D_{3g}(\mathcal{I}_1, \mathcal{I}_2) = 1 \Leftrightarrow \max(N(\mathcal{I}_1, \mathcal{I}_2), N(\mathcal{I}_2, \mathcal{I}_1)).$$

Les choix de la t-norme et de la t-conorme ne doivent pas être indépendants, les opérateurs de fusion ayant par couple une sémantique équivalente, de par leur dualité pour la complémentation :

$$tco(1 \Leftrightarrow \mathcal{I}_1, 1 \Leftrightarrow \mathcal{I}_2) = 1 \Leftrightarrow t(\mathcal{I}_1, \mathcal{I}_2).$$

Ainsi la t-norme somme bornée correspond à la t-conorme somme bornée, la t-norme produit algébrique à la t-conorme somme algébrique, et la t-norme minimum à la t-conorme maximum.

Au final, nous retenons les trois mesures de similarité :

$$S_{1}(\mathcal{I}_{1},\mathcal{I}_{2}) = \frac{\sum_{v(I) \in V(I)} \min \left(\mathcal{I}_{1}(v(I)), \mathcal{I}_{2}(v(I))\right)}{\sum_{v(I) \in V(I)} \max(\mathcal{I}_{1}(v(I)), \mathcal{I}_{2}(v(I)))},$$

$$S_{2g}(\mathcal{I}_{1},\mathcal{I}_{2}) = \max_{v(I) \in V(I)} t(\mathcal{I}_{1}(v(I)), \mathcal{I}_{2}(v(I))),$$

$$S_{3g}(\mathcal{I}_{1},\mathcal{I}_{2}) = \max(\min_{v(I) \in V(I)} tco(\mathcal{I}_{1}(v(I)), 1 \Leftrightarrow \mathcal{I}_{2}(v(I))),$$

$$\min_{v(I) \in V(I)} tco(\mathcal{I}_{2}(v(I)), 1 \Leftrightarrow \mathcal{I}_{1}(v(I)))).$$

image	information	floue
$\mathcal{I}_{atlas}$	morphologie et localisation de l'objet données par l'atlas	non
$\mathcal{I}_{cont}$	contrainte de localisation dans un objet englobant	non
$\mathcal{I}_{dir}$	direction par rapport à un objet connu	oui
$\mathcal{I}_{dist}$	distance à un objet connu	oui
${\cal I}_{mat}$	radiométrie de la matière constitutrice	oui
${\cal I}_{roi}$	région d'intérêt entourant l'objet	oui
$\mathcal{I}_{classe(i,c)}$	région de radiométrie homogène obtenue par classification	oui

TAB. 12.1 – Informations disponibles pour la fusion

#### 12.5.3 Informations disponibles

Le tableau 12.1 récapitule les différentes informations qu'ont pu nous donner les sous-étapes précédentes. Nous pouvons distinguer trois types distincts d'informations; celles qui traitent de la position de l'objet, de sa morphologie, et de sa radiométrie.

Les informations de localisation sont données par :

- $I_{cont}$ , contrainte ensembliste stricte (Cf. section 11.1.4), elle décrit la zone de recherche de l'objet, généralement très large,
- $I_{dir}$  et  $I_{dist}$ , dépendances spatiales vis-à-vis d'objets déjà reconnus, elles restreignent la zone de recherche mais donnent encore une localisation large de l'objet,
- $-\mathcal{I}_{roi}$ , information *a priori* provenant indirectement de l'atlas, et adaptée à l'image par le champ de correspondance, elle est volontairement moins large que les informations précédentes.

Ces informations sont de diverses sémantiques, et l'étendue des régions floues sont différentes, de par leur localisation et de par leur morphologie (Cf. la figure 12.8); ces informations sont donc complémentaires.

Contrairement à  $\mathcal{I}_{cont}$  et  $\mathcal{I}_{roi}$  qui sont deux images exprimées systématiquement à chaque étape, les informations  $\mathcal{I}_{dir}$  et  $\mathcal{I}_{dist}$  sont en nombre variable; ce nombre dépend de l'objet recherché à une étape donnée et de la liste des objets déjà reconnus.

Les informations morphologiques sont uniquement le fait de  $\mathcal{I}_{roi}$ . Ces informations sont donc très importantes lorsqu'il s'agit d'imposer une limite à l'objet anatomique.

Cette limite peut être difficilement observable, parce que gommée si l'objet est adjacent à un autre de même caractéristique radiométrique, et si leur séparation est trop fine ; c'est généralement le cas, par exemple, du putamen et du pallidum.



FIG. 12.8 – Informations à fusionner

Ces mêmes coupes présentent quatre informations différentes, qui nous renseignent sur la position du noyau caudé droit : en haut à gauche la contrainte binaire de localisation dans l'objet englobant cerveau, en haut à droite l'expression de « latéral au ventricule latéral droit », en bas à gauche la région d'intérêt floue tirée de l'atlas, et en bas à droite la radiométrie attendue, radiométrie moyenne de la substance grise. Cette limite peut même être fictive, car relativement arbitraire ; c'est le cas, par exemple, de celle du corps calleux dans l'axe perpendiculaire au plan inter-hémisphérique, ou de l'aire accumbens entre noyau lenticulaire et noyau caudé.

Les informations de type radiométrique, quant à elles, sont  $\mathcal{I}_{mat}$  et  $\mathcal{I}_{classe}$ .

La première reflète une connaissance *a priori* de la matière constitutrice de l'objet recherché (Cf. figure 12.8). La seconde, dont l'expression est multiple, reflète l'existence de modes radiométriques dans la région d'intérêt de l'image à traiter.

Le rôle de  $\mathcal{I}_{classe}$  est donc de nous proposer plusieurs régions de radiométrie homogène (Cf. section 12.4, il y en a 14). La fusion de ces informations entre elles ne pourrait avoir qu'un intérêt : faire ressortir les classes stables par les différentes classifications; nous ne pensons pas que cela puisse être très significatif, aussi nous ne les fusionnons pas entre elles.

Comme les classifications mises en œuvre sont non contextuelles, les régions qui en résultent ne sont pas toutes cohérentes spatialement; en revanche, puisque nous nous focalisons sur la zone de l'image qui entoure cet objet, la région qui correspond à l'objet recherché doit être relativement cohérente. Cette région est généralement une surestimation de la morphologie de l'objet.

Remarquons enfin que  $\mathcal{I}_{atlas}$  n'est qu'une information temporaire; trop particulière à l'image qui a servi à construire l'atlas, et donc trop certaine, elle cède sa place à  $\mathcal{I}_{roi}$  qui elle tient compte de l'imprécision due à la variabilité anatomique.

#### 12.5.4 Fusion et sélection

Un objet anatomique se traduit dans l'image par une cohérence spatiale et radiométrique. Nous proposons ici un schéma de fusion qui confronte ces deux natures de cohérence, afin de produire l'information floue qui décrit le mieux possible l'objet recherché.

D'après le tableau 12.1, nous disposons d'informations dont la sémantique de chacune est différente, mais aussi d'un lot d'informations  $\mathcal{I}_{classe(i,c)}$  issues des classifications (Cf. figure 12.7). Ces informations sont pour la plupart erronées, car représentent des régions non significatives de l'objet recherché; de plus, plusieurs informations peuvent correspondre à cet objet, mais avec une qualité variable (Cf. les trois vignettes de la quatrième ligne de la figure 12.7). Nous devons donc, parmi ces informations, sélectionner celle qui décrit le mieux l'objet recherché.

Nous sommes dans l'alternative suivante. Soit nous effectuons une sélection directement dans cet ensemble :

$$\{\mathcal{I}_{classe(i,c)}, c \in [2,5] \text{ et } i \in [2,c] \} \sim \mathcal{I}_{classe(i_{sel},c_{sel})},$$

soit nous effectuons une sélection en deux temps, tout d'abord dans les informations issues de chaque classification (présélection) :

$$\forall c \in [2,5] \{ \mathcal{I}_{classe(i,c)}, i \in [2,c] \} \quad \rightsquigarrow \quad \mathcal{I}_{classe(i_{sel},c)},$$

puis dans les informations retenues (sélection finale) :

$$\{ \mathcal{I}_{classe(i_{sel},c)}, c \in [2,5] \} \rightsquigarrow \mathcal{I}_{classe(i_{sel},c_{sel})}.$$

Nous avons préféré la seconde solution, qui offre une plus grande souplesse puisque deux modes différents de sélection peuvent être appliqués.

Afin de sélectionner une information parmi un ensemble d'informations, nous devons confronter chaque information de cet ensemble avec une information qui sert de référence, et qui est extérieure à cet ensemble. Une méthode de sélection est de retenir l'information qui maximise une mesure de similarité avec la référence (Cf. section 12.5.2). Comme notre étape de sélection est en deux temps, nous pouvons employer deux informations de référence distinctes :

 $- I_{sell}$ , critère de présélection de la meilleure classe de chaque classification,

 $-\mathcal{I}_{sel2}$ , critère de sélection dans la présélection.

Le premier critère se limite généralement à donner une indiquation approximative concernant la radiométrie attendue; quant au second, il reprend cette indiquation radiométrique lorsqu'elle est sûre, mais fait également intervenir en plus des considérations morphologiques.

Pour que la mesure de similarité ne soit pas biaisée par les informations extérieures à la région d'intérêt ou à la contrainte de localisation, nous conditionnons systématiquement les informations participantes :

$$\mathcal{I} \in \{\mathcal{I}_{sel1}, \mathcal{I}_{sel2}, \mathcal{I}_{classe(1,2)}, \dots, \mathcal{I}_{classe(5,5)}\},\$$

en formant:

$$\mathcal{I}' = \min \left( \mathcal{I}, \mathcal{I}_{roi}, \mathcal{I}_{cont} \right)$$
.

La présélection s'écrit alors :

$$\forall c \in [2,5] \quad \mathcal{I}_{classe(i_{sel},c)} \text{ vérifie } S(\mathcal{I}'_{classe(i_{sel},c)}, \mathcal{I}'_{sel1}) \geq S(\mathcal{I}'_{classe(i,c)}, \mathcal{I}'_{sel1}) \quad \forall i \in [1,c],$$

et la sélection:

$$\mathcal{I}_{classe(i_{sel},c_{sel})} \text{ vérifie } S(\mathcal{I}'_{classe(i_{sel},c_{sel})},\mathcal{I}'_{sel2}) \geq S(\mathcal{I}'_{classe(i_{sel},c)},\mathcal{I}'_{sel2}) \ \forall c \in [2,5].$$

Nous conservons donc une seule information issue des classifications:  $\mathcal{I}_{classe(i_{sel},c_{sel})}$ ; c'est la plus pertinente vis-à-vis des informations  $\mathcal{I}_{sel1}$  et  $\mathcal{I}_{sel2}$  qui servent de critères de sélection. Ces critères, différents pour chaque objet anatomique particulier, sont décrits dans le chapitre suivant.

L'ensemble des informations suivant est maintenant constitué d'éléments de sémantique disjointe :

 $- I_{cont}$ ,

```
- les \mathcal{I}_{dir} et \mathcal{I}_{dist}, en nombre variable,
```

- $-\mathcal{I}_{roi}$ ,
- $\mathcal{I}_{classe(i_{sel}, c_{sel})}.$

Une ultime étape consiste en la fusion de ces informations qui donne l'information  $\mathcal{I}_{fusion}$ . Dans cette fusion, la contrainte de localisation  $\mathcal{I}_{cont}$  n'est utilisée qu'en dernier lieu, et avec un opérateur min. Nous garantissons ainsi que l'objet que nous allons segmenter se trouve bien dans l'intérieur large de son objet englobant, et qu'il n'empiète pas sur les surfaces externes des objets déjà reconnus.

Cette ultime fusion, différente pour chaque objet anatomique particulier, est détaillée et illustrée dans le chapitre suivant.

### 12.5.5 Réalisation de la segmentation

De l'information floue  $\mathcal{I}_{fusion}$  nous devons déduire une segmentation de l'objet recherché. Cette information est en fait une image de niveaux de gris, et du fait de la classification non contextuelle, la cohérence spatiale de l'objet n'est pas encore tout à fait assurée.

Deux problèmes peuvent survenir si nous réalisons directement une binarisation de cette image :

- l'objet peut être connecté à d'autres objets qui ne nous intéressent pas,
- l'objet peut comporter des trous importants en nombre et en taille.

Le pire cas, que nous n'avons jamais rencontré, cumule ces deux problèmes. Suivant le type de l'objet, nous appliquons à  $\mathcal{I}_{fusion}$  des traitements numériques différents.

Lorsque l'objet est d'aspect volumique (par opposition à surfacique) : il s'agit d'une ouverture ou d'une fermeture morphologique, si nous sommes confrontés respectivement au premier ou au second problème. L'élément structurant employé est de petite taille : c'est une sphère de rayon 1,7 mm ; elle se traduit donc, en discret, par le 6-voisinage si l'image n'est pas trop anisotrope (ce qui est le cas de celles dont nous disposons), ou par un 4-voisinage si son anisotropie est trop prononcée.

Lorsque l'objet est d'aspect surfacique, seule la fermeture morphologique est appropriée (l'ouverture ferait disparaître en grande partie l'objet).

Généralement, ces traitements suffisent à l'obtention ultérieure de bons résultats, la fusion ayant produit une image de qualité déjà très correcte.

L'image  $\mathcal{I}_{fusion}$ , une fois traitée, doit être binarisée. Pour cela, l'algorithme répété des k-moyennes (Cf. section 5.2.4) nous fournit un seuil adapté à l'image; afin que l'objet résultant soit régularisé, nous effectuons avec ce seuil une binarisation contextuelle locale sur la moyenne (Cf. section 6.1.7 et figure 6.3). Comme précédemment avec les filtres morphologiques, le moyenneur est appliqué sur un 6- ou 4-voisinage, en fonction de l'anisotropie de l'image. En notant  $\mathcal{I}_{bin}$  cette binarisation, seuil la valeur du seuil, et G le voisinage, nous réalisons donc en chaque voxel :

$$m(v(I)) = \frac{1}{\operatorname{card}(G)} \sum_{w(I) \in G(v(I))} \mathcal{I}_{bin}(w(I)),$$

d'où la décision binaire :

$$\mathcal{I}_{bin}(v(I)) = \begin{cases} 0 & \text{si } m(v(I)) < seuil \\ 1 & \text{si } m(v(I)) \geq seuil \end{cases}$$

Nous sélectionnons alors la plus grande composante 18-connexe de  $\mathcal{I}_{bin}$ , dont nous bouchons ses éventuels trous ; ainsi, nous finissons de garantir les propriétés mentionnées en section 11.1.4.

Une (ré)estimation par érosion des statistiques radiométriques de l'objet (décrite en section 8.3) termine enfin cette sous-étape, en mettant à jour l'information radiométrique concernant cet objet (Cf. section 12.2.4).

Cette dernière sous-étape, avant la mise à jour du champ de déformation, s'apparente à un posttraitement de la fusion d'informations; elle peut prendre des formes légèrement différentes suivant les objets. Ces points seront détaillés et illustrés dans le chapitre suivant.

### 12.6 Conclusion

Dans ce chapitre, nous avons présenté l'ensemble des outils que nous manipulons au cours de notre procédure de reconnaissance, à l'exception du champ de correspondance, traité au chapitre 11.

Ces outils exploitent les conclusions des trois premières parties.

- (a) Les relations entre objets, dont nous avions montré l'importance en section 1.7, sont maintenant mises en œuvre.
  - (b) La modélisation des lois radiométriques des objets est gaussienne, en accord avec les tests réalisés en section 2.3.
- 2. (a) L'algorithme répété des *k*-moyennes, donné en section 5.2.4, est employé pour fournir des classifications robustes, grâce à la restriction à une région d'intérêt de l'histogramme radiométrique.
  - (b) Les valeurs d'appartenance aux classes floues qui s'en déduisent n'ont pas le défaut, mentionné en section 5.3.4, de celles des *c*-moyennes floues.
- 3. (a) La décision binaire est contextuelle locale, car nous avions noté les bons résultats de régularisation d'une telle approche en section 6.3.2.
  - (b) La procédure s'appuie sur la segmentation morphologique du cerveau, présentée en section 7.2.
  - (c) Les statistiques radiométriques sont réestimées à l'issue des segmentations, selon la méthode développée dans la section 8.3.

Un aspect récurrent de notre approche est l'utilisation de la théorie des ensembles flous, qui permet d'exprimer divers types d'informations, tout en tenant compte de leur imprécision. Ce sont :

- les relations spatiales de direction et de distance d'un objet par rapport à un objet de référence,
- la radiométrie attendue d'un objet connaissant sa matière constitutrice,
- la région d'intérêt dans laquelle doit se trouver un objet,
- et l'existence de classes radiométriques.

Enfin, la fusion floue d'informations nous permet de combiner ces informations, et de repousser la segmentation des objets recherchés en fin d'étape.

## Chapitre 13

# Mise en œuvre de la reconnaissance

Notre procédure de reconnaissance, présentée au chapitre 10 et détaillée dans les chapitres 11 et 12, peut maintenant être mise en œuvre.

Ce dernier chapitre donne, pour chaque structure, la liste des informations floues que nous pouvons former, ainsi que le mode d'utilisation de ces informations, et les méthodes finales de binarisation et de segmentation (section 13.1). Ce chapitre est illustré par les résultats obtenus (section 13.2), qui sont ensuite commentés (section 13.3).

### 13.1 Application de la méthode de reconnaissance aux différentes structures

Dans ce chapitre, pour des raisons de lisibilité, toute visualisation d'un champ tridimensionnel de vecteurs est restreinte à une décimation; sur la coupe d'un champ, un vecteur sur 9 est représenté<sup>1</sup>, et seule sa projection sur le plan de coupe apparaît.

De plus, dans chaque visualisation, un vecteur ne représente pas le vecteur de correspondance issu du calcul, mais la différence entre ce vecteur de correspondance et un vecteur de correspondance, issu d'un champ obtenu à une étape antérieure ; nous visualisons donc des champs de correspondance relative. Ce procédé masque la forte variation globale, et permet de mieux apprécier les variations locales d'une étape à une autre.

L'initialisation du champ de correspondance s'effectue avec l'objet cerveau, segmenté par morphologie mathématique dans l'image à traiter (section 7.2). Le champ de correspondance obtenu est visualisé en figure 13.1 sur une coupe axiale.

En section 9.1.2, nous avons évoqué la normalisation de Talairach qui s'appuie sur la boîte englobante du cerveau. La mise en correspondance surfacique du cerveau et l'extension de la correspondance au volume cérébral font penser à cette contrainte. Cependant, nous tenons compte de la surface cérébrale, et non pas seulement de la boîte englobante du cerveau.

La normalisation de Talairach est multi-linéaire par morceaux. Dans notre approche, le modèle impose que la déformation soit de variation spatiale constante (Cf. section 11.3.1). La déformation est

<sup>1.</sup> curiosité due au fait que  $\sqrt{10} \notin \mathbb{N}$  !

donc de forme beaucoup plus libre, et prend facilement en compte les déformations locales, imposées par la surface cérébrale.

En revanche, en l'absence d'un repérage intérieur au cerveau (qui n'apparaît qu'à la fin de la première étape), nous ne pouvons pas affirmer que la déformation donnée par cette initialisation soit meilleure que celle de Talaraich.



FIG. 13.1 – Initialisation du champ de correspondance avec l'objet cerveau (coupe axiale)

Cette coupe axiale montre la différence entre le champ de correspondance résultant de l'initialisation et le champ qui fait correspondre le volume de l'image avec celui de l'atlas. Elle visualise donc la différence de position du cerveau dans les deux volumes, et l'extension du champ à l'intérieur de l'objet cerveau.

Les figures 13.2, 13.4, 13.6, 13.8, 13.10, et 13.11 sont formées de façon identique. Elles sont constituées de quatre vues d'une région de l'image *I* à traiter (cette région peut varier d'une figure à l'autre).

La première vue, en haut à gauche, superpose aux valeurs radiométriques de I la surface de l'objet recherché (en blanc). Cette surface est extraite de l'information binaire  $I_{atlas}$  obtenue à l'issue de la
sous-étape 1, transformée inverse de l'objet de référence équivalent donné par l'atlas.

La deuxième vue, en haut à droite, montre jusqu'à l'étape 3 incluse l'information  $\mathcal{I}'_{sel2}$ , qui permet la sélection finale d'une des informations issue des classifications (sous-étape 5 et section 12.5.4). Cette information de sélection provient de la fusion d'informations qui décrivent l'objet recherché :

$$\mathcal{I}_{sel2}' = \min\left(\mathcal{I}_{sel2}, \mathcal{I}_{roi}, \mathcal{I}_{cont}\right).$$

A partir de l'étape 4, la deuxième vue montre :

$$\min(\mathcal{I}_{roi}, \mathcal{I}_{cont})$$

car dans les dernières étapes, aucune autre information que la radiométrie, la région d'intérêt floue, et la contrainte de localisation, n'est utilisée pour les sélections.

La troisième vue, en bas à gauche, donne le résultat  $\mathcal{I}_{fusion}$  de la fusion qui prend en compte l'ensemble des informations disponibles, dont fait partie l'information radiométrique sélectionnée.

Enfin la dernière vue, en bas à droite, superpose à I la surface de l'objet segmenté ( $surf(O_{VLTd})$ ), objet résultat d'une étape de notre procédure de reconnaissance.

La section 13.2 suivante reprend ce dernier type de visualisation de façon exhautive; plusieurs planches, axiales, coronales, et sagittales, permettent alors d'apprécier les résultats de la reconnaissance dans leur globalité.

### 13.1.1 Ventricule latéral droit

La première étape a pour but de reconnaître le ventricule latéral droit.

Pour ce ventricule, l'information  $\mathcal{I}_{atlas}$  est obtenue par le champ qui met en correspondance l'objet cerveau de l'image *I* avec celui de l'atlas. Le ventricule de référence, une fois replacé dans *I*, est localisé à proximité du ventricule de l'image à traiter (figure 13.2, en haut à gauche). Notre modèle de déformation, uniquement contraint par la surface cérébrale, semble approprié à notre problématique; il fournit une initialisation déjà proche du résultat souhaité.

Les informations qui décrivent le ventricule latéral droit sont les suivantes.

- La contrainte de localisation  $\mathcal{I}_{cont}$  traduit le fait que le ventricule a le cerveau pour objet englobant (Cf. section 12.2.1).
- L'information radiométrique  $\mathcal{I}_{LCR}$  est approximative (Cf. section 12.2.4); elle provient de l'estimation statistique des trois matières principales (liquide céphalo-rachidien, substance grise, substance blanche) décrite en section 5.4, et menée pour la segmentation morphologique du cerveau décrite en section 7.2.
- L'information  $\mathcal{I}_{roi}$  est obtenue par dilatation floue de  $\mathcal{I}_{atlas}$  (Cf. section 12.3); l'élément structurant sphérique a un noyau de 1 cm et un support de 1,5 cm.
- La seule information information de distance traduit le fait que les ventricules latéraux sont « bien à l'intérieur du cerveau »; nous la notons  $\mathcal{I}_{dist}$  (Cf. section 12.2.3).
- Enfin, les dernières informations  $\mathcal{I}_{classe(i,c)}$  sont issues des classifications (Cf. section 12.4).

Les informations de présélection et de sélection, notées respectivement  $\mathcal{I}_{sel1}$  et  $\mathcal{I}_{sel2}$  (Cf. section 12.5.4), sont :

$$\mathcal{I}_{sel1} = \mathcal{I}_{LCR}$$



FIG. 13.2 – Etape 1 : reconnaissance du ventricule latéral droit

et :

$$\mathcal{I}_{sel2} = \mathcal{I}_{dist}$$
.

La présélection est déterminée par l'accord radiométrique d'une classe avec la connaissance radiométrique *a priori*, et la sélection, uniquement par l'accord avec les informations de localisation.

En effet, cet accord s'effectue avec une mesure de similarité entre les informations de classe et de sélection, après que toutes les informations ont été conditionnées (avec l'opérateur min) par  $\mathcal{I}_{cont}$  et  $\mathcal{I}_{roi}$ ; ces deux dernières informations interviennent donc implicitement dans chaque phase de sélection.

Nous avons constaté empiriquement que la sélection n'est pas affectée par le choix de la mesure de similarité; parmi les trois mesures retenues en section 12.5.2, nous avons alors choisi  $S_1$  pour sa rapidité d'exécution.

Formons l'information de localisation:

$$\mathcal{I}_{localisation} = Fu_{\text{movenne arithmétique}}(\mathcal{I}_{roi}, \mathcal{I}_{dist})$$

pour obtenir l'information finale, visualisée en bas à gauche de la figure 13.2 :

 $\mathcal{I}_{fusion} = \min(\mathcal{I}_{cont}, Fu_{\text{moyenne géométrique}}(\mathcal{I}_{classe(i_{sel}, c_{sel})}, \mathcal{I}_{localisation})).$ 

Nous pouvons observer que, du fait de l'imprécision des informations de localisation du ventricule latéral droit, une partie du ventricule latéral gauche reste présente. Cette imprécision est nécessaire parce que le champ n'est induit que par la surface cérébrale, donc approximatif au centre du cerveau, et parce que la variabilité inter-individus de la morphologie des ventricules est assez importante.

Avant de segmenter le ventricule latéral droit, une ouverture morphologique est appliquée à  $\mathcal{I}_{fusion}$ ; elle garantit que ce ventricule sera bien déconnecté des autres composantes du système ventriculaire : le ventricule latéral gauche, les trous de Monro, et le troisième ventricule. La binarisation contextuelle locale et l'étiquetage qui retient la composante connexe de plus grande taille déterminent l'objet segmenté. Sa surface est représentée en bas à droite de la figure 13.2.

La moyenne et l'écart-type de la loi radiométrique gaussienne du liquide céphalo-rachidien sont alors réestimés.

Le champ de correspondance est alors modifié en deux temps ; les correspondances surfaciques sont calculées, puis les valeurs du champ sont mises à jour à l'intérieur de l'objet cerveau (qui possède maintenant un trou) et à l'intérieur du ventricule. Les modifications du champ de correspondance sont observables sur la figure 13.3, qui montre la différence entre le champ de correspondance issu de la première étape, et celui qui provient de l'initialisation (figure 13.1).

Cette figure permet d'aprécier les différences de localisation et de morphologie entre le ventricule latéral droit de référence et celui de l'image à traiter ; ces différences s'affranchissent de la variabilité des surface cérébrales respectives de A et I, puisque les deux volumes cérébraux ont déjà été mis en correspondance.

En particulier, le ventricule latéral droit de A est légèrement postérieur à celui de I, les vecteurs de correspondance étant globalement dirigés vers le bas de la coupe axiale. De plus, la tête du ventricule latéral droit de A est de volume plus important que celle de I (les vecteurs de correspondance s'écartant latéralement). Enfin, l'apex du ventricule latéral droit de A est moins latéral que celui de I.



FIG. 13.3 – Modification du champ de correspondance après l'étape 1

Cette coupe axiale montre la différence entre le champ de correspondance qui résulte de l'étape 1 et celui qui résulte de l'initialisation (figure 13.1); les objets considérés sont le cerveau et le ventricule latéral droit.

#### 13.1.2 Ventricule latéral gauche

La deuxième étape a pour but de reconnaître le ventricule latéral gauche.

Le ventricule latéral gauche de référence  $\mathcal{I}_{atlas}$ , donné par l'atlas et transformé à l'aide du champ de correspondance résultant de l'étape précédente, est représenté par sa surface, superposée à I, en haut à gauche de la figure 13.4.





FIG. 13.4 – Etape 2 : reconnaissance du ventricule latéral gauche

Les informations qui le décrivent sont les suivantes.

 $- I_{cont}$ , contrainte spatiale qui exprime que le ventricule est inscrit dans l'objet cerveau, tient compte de la présence du ventricule latéral droit ; cette information est plus restrictive qu'à

l'étape précédente.

- $\mathcal{I}_{LCR}$ , information de radiométrie *a priori*, est plus précise qu'à la première étape car les statistiques radiométriques ont depuis été réestimées.
- $I_{roi}$  est déduite de  $I_{atlas}$ , comme lors de l'étape précédente, par un élément structurant sphérique de 1 cm de noyau et de 1,5 cm de support.
- $I_{dist}$ , qui indique qu'un ventricule latéral est bien à l'intérieur du cerveau, est réutilisée.
- Comme nous avons reconnu le ventricule latéral droit, nous pouvons exprimer que, par rapport à ce dernier, le ventricule gauche que nous recherchons se trouve dans la direction médiale (soit à droite dans l'image vu en vue axiale); cette information est  $\mathcal{I}_{dir}$ .
- Enfin, les  $\mathcal{I}_{classe(i,c)}$  donnent les modes radiométriques de l'image I sur  $\mathcal{I}_{roi}$ .

Les informations de présélection et de sélection sont respectivement :

$$\mathcal{I}_{sel1} = \min(\mathcal{I}_{LCR}, \mathcal{I}_{dir}),$$

et:

$$\mathcal{I}_{sel2} = \min\left(\mathcal{I}_{dist}, \mathcal{I}_{dir}\right).$$

L'information  $\mathcal{I}_{sel2}$ , après son conditionnement par  $\mathcal{I}_{cont}$  et  $\mathcal{I}_{roi}$ , est représentée en haut à droite de la figure 13.4. Par rapport à l'information équivalente, utilisée lors de l'étape précédente, elle est beaucoup plus restrictive, donc plus précise. La contrainte spatiale apparaît sur la représentation sous la forme d'une tâche blanche; cette tâche correspond à la tête du ventricule latéral droit, et provient du caractère binaire de la contrainte spatiale, et de l'opérateur min employé pour le conditionnement. L'information directionnelle, quant à elle, défavorise la recherche du ventricule latéral gauche du mauvais côté du premier ventricule segmenté; cela se traduit sur la représentation par une information plus claire à gauche de la tâche blanche.

Enfin, la fusion est réalisée suivant:

$$\mathcal{I}_{localisation} = Fu_{\text{movenne arithmétique}}(\mathcal{I}_{roi}, \mathcal{I}_{dist})$$

pour obtenir l'information finale, visualisée en bas à gauche de la figure 13.2 :

$$\mathcal{I}_{fusion} = \min(\mathcal{I}_{cont}, \mathcal{I}_{dir}, Fu_{\text{moyenne géométrique}}(\mathcal{I}_{classe(i_{sel}, \mathcal{C}_{sel})}, \mathcal{I}_{localisation}))$$

L'information directionnelle  $\mathcal{I}_{dir}$ , fusionnée avec un opérateur minimum, est donc une contrainte de localisation plus sévère que ne le sont les informations de localisation *a priori*  $\mathcal{I}_{roi}$  et de distance à la surface du cerveau  $\mathcal{I}_{dist}$ , fusionnées avec une moyenne. Cela se justifie car cette information est sûre, de par la symétrie des deux ventricules latéraux, tout en étant très large comme le montre la figure 12.3.

La segmentation, pour les mêmes raisons qu'à l'étape précédente, commence par une ouverture morphologique effectuée sur  $\mathcal{I}_{fusion}$ , ensuite binarisée. La recconnaissance se termine par l'obtention de l'objet de plus grande composante connexe.

Les caractéristiques statistiques sont de nouveau réévaluées, mais en tenant compte cette fois-ci des deux ventricules latéraux.

Enfin, le champ de déformation est actualisé, ce que représente la figure 13.5. La prise en compte du ventricule latéral gauche modifie le champ dans l'hémisphère gauche, et n'influe pas de façon perceptible sur l'hémisphère droit.



FIG. 13.5 – Modification du champ de correspondance après l'étape 2

Cette coupe axiale montre la différence entre le champ de correspondance qui résulte de l'étape 2 et celui qui résulte de l'initialisation (figure 13.1); les objets considérés sont le cerveau et les ventricules latéraux.

## 13.1.3 Noyau caudé droit

La troisième étape a pour but de reconnaître le noyau caudé droit, dont la localisation anatomique est fortement liée à celle du ventricule latéral droit. Le champ de correspondance tenant compte du ventricule, le noyau de référence défini par l'atlas vient se placer contre le ventricule de l'image, comme le montre la figure 13.6 (en haut à gauche).





FIG. 13.6 – Etape 3 : reconnaissance du noyau caudé droit

Les informations qui décrivent le noyau caudé droit sont :

- $\mathcal{I}_{cont}$ , contrainte spatiale qui restreint la recherche au volume cérébral, privé des volumes des ventricules latéraux,
- $I_{SGR}$ , information de radiométrie *a priori*, approximative, car obtenue à l'issue de la segmentation du cerveau,
- $I_{roi}$ , déduite de  $I_{atlas}$  par dilation floue avec un élément structurant sphérique de 0,5 cm de noyau et de 1 cm de support,

 $- I_{dir}$ , qui indique que le noyau caudé droit est latéral au ventricule latéral droit,

- les  $\mathcal{I}_{classe(i,c)}$ , qui donnent les modes radiométriques de I sur  $\mathcal{I}_{roi}$ .

Les informations de présélection et de sélection sont formées suivant :

$$\mathcal{I}_{sel1} = \min\left(\mathcal{I}_{SGR}, \mathcal{I}_{dir}\right),\,$$

et:

$$\mathcal{I}_{sel2} = \mathcal{I}_{dir}$$
.

Comme aux étapes précédentes, l'information radiométrique n'intervient donc que dans le choix d'une classe dans chaque classification, et la sélection finale est réalisée uniquement avec les informations de localisation.

 $\mathcal{I}'_{sel2}$ , conditionnement de  $\mathcal{I}_{sel2}$  par  $\mathcal{I}_{cont}$  et  $\mathcal{I}_{roi}$ , est représentée sur la figure 13.6 en haut à droite.

L'information de fusion est formée suivant :

$$\mathcal{I}_{localisation} = F u_{\text{movenne arithmétique}} (\mathcal{I}_{roi}, \mathcal{I}_{dir})$$

pour obtenir l'information finale, visualisée en bas à gauche de la figure 13.2 :

 $\mathcal{I}_{fusion} = \min(\mathcal{I}_{cont}, Fu_{\text{moyenne géométrique}}(\mathcal{I}_{classe(i_{sel}, c_{sel})}, \mathcal{I}_{localisation})).$ 

Une ouverture morphologique réalisée sur  $\mathcal{I}_{fusion}$  est nécessaire afin d'éliminer toute connexion avec le putamen et avec le thalamus. Une binarisation et un étiquetage de la plus grande composante donne l'objet recherché.

Une évaluation précise des caractéristiques radiométriques du noyau caudé droit est effectuée. Comme nous le constatons sur le tableau 2.5, les différents noyaux ont des caractéristiques proches mais non identifiques; l'information radiométrique doit donc être distincte pour chaque noyau de type différent. Ici, nous retenons donc l'information  $\mathcal{I}_{NCA}$  pour les noyaux caudés; elle nous sert également d'approximation de l'information radiométrique  $\mathcal{I}_{NBA}$  qui concerne les noyaux de la base, information moins approximative que ne l'était  $\mathcal{I}_{SGR}$  qui concernait la substance grise dans sa globalité.

Au final, l'influence de ce noyau sur le champ de déformation est plus globale que celle des objets reconnus lors des étapes précédentes. Sur la figure 13.7, nous pouvons voir que l'ensemble des vecteurs sont touchés ; cela est dû à l'anatomie particulière de l'image, antagoniste par rapport à l'atlas. Du point de vue de la position et de la morphologie relatives des cerveaux de l'atlas référence et de l'image, le noyau caudé droit de I est légèrement postérieur au noyau de référence (ce qui se traduit sur la figure par des vecteurs dirigés vers le haut), tandis que le ventricule latéral droit de l'image est légèrement antérieur au ventricule de référence (ce qui se traduit par des vecteurs dirigés vers le bas).

De façon plus générale, nous pouvons affirmer que le champ de déformation, défini par la surface cérébrale et par des structures centrales qui forment un véritable volume au sein de l'hémisphère droit du cerveau, est donc maintenant bien formé pour décrire l'ensemble des structures centrales de cet hémisphère.



FIG. 13.7 – Modification du champ de correspondance après l'étape 3

Cette coupe axiale montre la différence entre le champ de correspondance qui résulte de l'étape 3 et celui qui résulte de l'initialisation (figure 13.1); les objets considérés sont le cerveau, les ventricules latéraux, et le noyau caudé droit.

### 13.1.4 Putamen droit

La quatrième étape a pour but de reconnaître le putamen droit. Le champ de correspondance, rendu très précis sur l'aire centrale droite du cerveau grâce aux étapes précédentes, donne une information *a priori*  $\mathcal{I}_{atlas}$  presque parfaite pour le putamen droit; la surface *a priori* du putamen, superposée à l'image (en haut à gauche de la figure 13.8), en témoigne.



FIG. 13.8 – Etape 4: reconnaissance du putamen droit

Les informations qui décrivent le putamen droit sont limitées aux informations « classiques », à défaut d'autres informations disponibles concernant le putamen :

- $\mathcal{I}_{cont}$ , contrainte spatiale,
- $I_{NBA}$ , information de radiométrie *a priori* des noyaux de la base,
- $-I_{roi}$ , obtenue avec un élément structurant sphérique de 0,5 cm de noyau et de 1 cm de support,
- $\mathcal{I}_{classe(i,c)}$ , informations des modes radiométriques.

En conséquence, les informations de présélection et de sélection sont identiques, et réduites à :

$$\mathcal{I}_{sel2} = \mathcal{I}_{sel1} = \mathcal{I}_{NBA}$$

et la fusion est réalisée suivant :

$$\mathcal{I}_{fusion} = \min(\mathcal{I}_{cont}, Fu_{\text{moyenne géométrique}}(\mathcal{I}_{classe(i_{sel}, c_{sel})}, \mathcal{I}_{roi})).$$

Le résultat de la fusion est donné en bas à gauche de la figure 13.8.

Les informations fusionnées subissent une ouverture morphologique afin d'éliminer le claustrum qui longe le côté latéral du putamen, puis une binarisation, et la plus grande composante est conservée. L'information radiométrique  $\mathcal{I}_{PUT}$  est calculée, et le champ de correspondance mis à jour (figure 13.9).

L'ouverture a malheureusement rogné la partie postérieure du putamen. Le recalage surfacique, à cause de son caractère non élastique, tend à compenser ce défaut puisqu'il fait correspondre les centres de masse respectifs des objets de l'atlas et de l'image : le champ de correspondance tire donc dans la direction postérieure le putamen reconnu. Cela se traduit sur l'illustration du champ, en figure 13.9, par l'orientation vers le bas des vecteurs localisés dans la région du putamen.

### 13.1.5 Quatrième ventricule

Les deux dernières étapes que nous avons mises en œuvre ont pour but de montrer que notre procédure peut effectivement prétendre à la reconnaissance de structures anatomiques délicates à segmenter.

De telles structures sont de petite taille, de forme complexe, de contexte spatial défavorable, voire combinent plusieurs de ces difficultés. Les quatrième et troisième ventricules font partie de cette catégorie de structures, puisqu'ils occupent chacun environ 0,1 % du volume cérébral. A notre connaissance, ils n'ont jamais été segmentés de façon automatique.

La cinquième étape traite la reconnaissance automatique du quatrième ventricule.

Nous n'avons pas pour l'instant reconnu de structures voisines du quatrième ventricule; ce ventricule est situé dans le tronc cérébral, très en-dessous des structures précédentes. L'erreur de localisation, due au champ de déformation encore très approximatif pour la partie inférieure de l'encéphale, est visualisée en haut à gauche sur la figure 13.10.

Les informations qui décrivent le quatrième ventricule sont limitées (comme lors de l'étape précédente):

 $- \mathcal{I}_{cont}$ , contrainte spatiale,

 $- I_{LCR}$ , information de radiométrie *a priori* des noyaux de la base,

 $-I_{roi}$ , obtenue avec un élément structurant sphérique de 0,5 cm de noyau et de 1,5 cm de support,

 $- I_{classe(i,c)}$ , informations des modes radiométriques.

Les informations de présélection et de sélection sont une nouvelle fois identiques :

$$\mathcal{I}_{sel2} = \mathcal{I}_{sel1} = \mathcal{I}_{LCR};$$

il en est de même pour la fusion :

$$\mathcal{I}_{fusion} = \min\left(\mathcal{I}_{cont}, Fu_{\text{moyenne géométrique}}\left(\mathcal{I}_{classe(i_{sel}, c_{sel})}, \mathcal{I}_{roi}\right)\right),$$



FIG. 13.9 – Modification du champ de correspondance après l'étape 4

Cette coupe axiale montre la différence entre le champ de correspondance qui résulte de l'étape 4 et celui qui résulte de l'initialisation (figure 13.1); les objets considérés sont le cerveau, les ventricules latéraux, le noyau caudé droit, et le putamen droit.



 $surf(\mathcal{I}_{atlas})$ 



 $\mathcal{I}_{roi}$ 



 $\mathcal{I}_{fusion}$ 



FIG. 13.10 – Etape 5 : reconnaissance du quatrième ventricule

dont le résultat est porté en bas à gauche de la figure 13.10.

Les informations fusionnées subissent une ouverture morphologique afin d'éliminer les deux structures fines et connexes au quatrième ventricule que sont : l'aqueduc de Sylvius, qui lui est supérieur, et la moelle épiniaire, qui lui est inférieure. De façon classique, une binarisation et la conservation de la plus grande composante donnent le résultat (en bas à droite de la figure 13.10). Le champ de correspondance est mis à jour.

### 13.1.6 Troisième ventricule

La sixième et dernière étape qui illustre notre procédure dans ce manuscrit consiste à reconnaître le troisième ventricule. Son mode opératoire est le même que celui de l'étape précédente, à deux détails près.

La dilatation pour l'obtention d'une région d'intérêt floue est faible, car la localisation donnée par l'information *a priori* de l'atlas est très bonne (en haut à gauche figure 13.11). En effet, le champ de correspondance étant contraint par les ventricules latéraux et par le quatrième ventricule, la position du troisième ventricule est inférée avec précision.



FIG. 13.11 – Etape 6: reconnaissance du troisième ventricule (vue sagittale)

Le contexte radiométrique du troisième ventricule pose des problèmes à cause de la présence de la citerne quadrijumelle, remplie de liquide céphalo-rachidien, située postérieurement à ce ventricule, et avec laquelle il est connexe (elle est observable sur la figure, juste en-dessous du splenium du corps calleux).

Nous prenons donc un élément structurant sphérique de noyau 0 mm et de support 4 mm, ce qui donne une région peu floue (en haut à droite figure 13.11). Cette faible dilatation conditionne fortement la localisation du troisième ventricule, ce que nous pouvons nous permettre.

La seconde différence avec l'étape précédente est que nous n'opérons pas d'ouverture morphologique sur l'information fusionnée. Contrairement aux étapes où il s'agissait de garantir la déconnexion entre l'objet recherché et d'autres objets, fins et connexes, ou tout simplement proches, cette déconnexion n'a pas lieu d'être ici, puisque la région d'intérêt, très restrictive, l'effectue lors de la fusion. Le champ de déformation issu des deux dernières étapes est représenté dans la figure 13.12 sur une coupe sagittale. Nous constatons sur ce champ l'influence des troisième et quatrième ventricules.



FIG. 13.12 – Modification du champ de correspondance après l'étape 6 (vue sagittale)

Cette coupe sagittale, située dans le plan inter-hémisphérique, montre la différence entre le champ de correspondance qui résulte de l'étape 2 et celui qui résulte de l'initialisation. Les objets considérés sont ceux qui ont été reconnus jusqu'à cette étape ; par rapport à la figure 13.9, le champ tient compte de deux nouveaux objets : les troisième et quatrième ventricules.

# **13.2** Présentation des résultats

Le résultat final de la reconnaissance des six structures cérébrales que nous avons traitées est donnée sur deux double planches dans les trois plans de coupe, et sur des vues en trois dimensions.

La double planche A représente en superposition à l'image I les surfaces des trois structures segmentées :

- le ventricule latéral droit,
- le putamen droit,
- et le troisième ventricule.

Cette première double planche est, pour chaque plan de coupe, répartie sur deux figures ; ce sont 13.13 et 13.14 pour les coupes axiales, 13.17 et 13.18 pour les coupes coronales, et 13.21 et 13.22 pour les coupes sagittales.

La double planche B représente en superposition à l'image I les surfaces des trois structures segmentées :

- le ventricule latéral gauche,
- le noyau caudé droit,
- et le quatrième ventricule.

Cette seconde double planche est, pour chaque plan de coupe, répartie sur deux figures; ce sont 13.15 et 13.16 pour les coupes axiales, 13.19 et 13.20 pour les coupes coronales, et 13.23 et 13.24 pour les coupes sagittales.

Nous visualisons ensuite, rendus en trois dimensions (figures 13.25 et 13.26), le système ventriculaire et les noyaux de la base de l'atlas, et ces mêmes structures, obtenues automatiquement par notre procédure de reconnaissance dans l'image  $x avT_1$ .



FIG. 13.13 – Reconnaissance – planche A, vue axiale 1/2



FIG. 13.14 – Reconnaissance – planche A, vue axiale 2/2



FIG. 13.15 – Reconnaissance – planche B, vue axiale 1/2



FIG. 13.16 – Reconnaissance – planche B, vue axiale 2/2



FIG. 13.17 – Reconnaissance – planche A, vue coronale 1/2



FIG. 13.18 – Reconnaissance – planche A, vue coronale 2/2



FIG. 13.19 – Reconnaissance – planche B, vue coronale 1/2



FIG. 13.20 – Reconnaissance – planche B, vue coronale 2/2



FIG. 13.21 – Reconnaissance – planche A, vue sagittale 1/2



FIG. 13.22 – Reconnaissance – planche A, vue sagittale 2/2



FIG. 13.23 – Reconnaissance – planche B, vue sagittale 1/2



FIG. 13.24 – Reconnaissance – planche B, vue sagittale 2/2



FIG. 13.25 – Reconnaissance – vue 3D du système ventriculaire

La vue du haut représente une partie du système ventriculaire tel qu'il est défini dans l'atlas A; les objets visualisés sont les ventricules latéraux gauche et droite (en plus foncé), le troisième ventricule (en plus clair), et le quatrième ventricule (en gris intermédiaire). La vue du bas montre le résultat de notre procédure de reconnaissance pour ces objets dans l'image  $I = xavT_1$ . Ces objets numériques tridimensionnels, constitués de voxels, donnent lieu à une triangulation de leur surface, et à un lissage de cette triangulation, afin que le rendu paraisse plus réaliste.



FIG. 13.26 - Reconnaissance - vue 3D des ventricules latéraux et des noyaux

Cette figure est réalisée de la même façon que la figure 13.25. La vue du haut montre les ventricules latéraux, le noyau caudé droit, et le putamen droit, extraits de l'atlas A. Les deux vues du bas représentent ces mêmes objets, reconnus dans  $I = xavT_1$  par notre procédure.

# 13.3 Commentaire des résultats

Les résultats que nous avons montré correspondent à quelques structures dont l'ensemble est représentatif des difficultés que nous pouvons rencontrer, avec des structures de forme et de localisation très variées. Ils ne sont donc pas exhaustifs, mais leur bonne qualité est prometteuse.

S'ils sont bien meilleurs que ceux des approches des parties II et III, ils ne sont cependant pas exempts de défauts.

En particulier, un défaut récurrent des structures reconnues est qu'elles sont sous-segmentées.

L'ouverture morphologique, appliquée à l'information issue de la fusion avant que la binarisation n'ait lieu, a tendance à faire disparaître les parties les plus fines des objets anatomiques. Elle est cependant utile pour déconnecter ces objets d'autres objets voisins, bien que cette déconnexion soit déjà favorisée par la sévérité de la classification vis-à-vis de l'effet de volume partiel.

Aussi, en garantissant l'isolement des ventricules latéraux par rapport au troisième ventricule, par l'effacement des trous de Monro, nous perdons la partie antérieure de la tête de ces ventricules et une portion de l'apex. Pour le putamen droit, bien disjoint du claustrum, c'est sa queue qui est oubliée dans les coupes axiales supérieures. Le quatrième ventricule, correctement dissocié du liquide céphalo-rachidien des citernes voisines, y laisse ses récessus latéraux ; il conserve malheureusement une partie de l'acqueduc de Sylvius. Le troisième ventricule, quant à lui, n'a plus sa partie supérieure à l'adhérence inter-thalamique ; en revanche, l'aqueduc de Sylvius, les trous de Monro, et surtout la citerne quadrijumelle sont heureusement écartés.

L'allure du champ de déformation résultant des étapes de reconnaissance est visualisée sur une planche de coupes axiales (figure 13.27) de l'espace de l'atlas. Cette visualisation illustre que les déformations imposées par les surfaces d'objets ont une incidence trop locale sur le champ. Cela s'explique par l'utilisation d'un critère d'arrêt de l'algorithme d'extension du champ pas assez sévère (Cf. section 11.3.5).

Nous avons fixé  $\epsilon$  à 0,005; pour une déformation moins locale, donc plus lissée et plus précise, il faudrait qu' $\epsilon$  soit beaucoup plus faible. Une mise en œuvre multi-échelles de l'algorithme d'extension pourrait éliminer ce défaut, tout en conservant un temps de calcul raisonnable.



FIG. 13.27 – Champ de déformation après les 7 étapes

Le mode de représentation de cette planche est similaire à celui des figures 11.4 et 11.5, mais ne représente (en noir) que les voxels de l'atlas qui n'ont pas de voxels antécédents par la déformation directe  $F_E: I \to A$ .

# 13.4 Conclusion

La mise en œuvre de notre procédure de reconnaissance a été l'occasion de constater sa robustesse vis-à-vis de la variété des structures à segmenter.

La fusion d'informations, pour constituer les informations de sélection et l'information numérique finale, est intuitive. Nous avons privilégié les opérateurs de compromis, afin d'être ni trop sévère ni trop indulgent. Leur principal défaut est connu : la fusion résultante n'est pas très discriminante. Néanmoins nous obtenons, après la sélection des informations radiométriques et après la binarisation, les résultats escomptés ; cela laisse à penser qu'une finesse dans les procédés de fusion n'est pas indispensable.

Le choix des informations sur lesquelles s'appuie les sélections est effectué aussi de façon très intuitive. Pour la sélection d'une classe dans une classification, l'emploi d'une information de radiométrie *a priori* est un bon discriminant. Quant à la sélection finale, la fusion de toutes informations *a priori*, de préférence non radiométriques, fournit également un bon discriminant, le type de la mesure de similarité employée n'affectant pas le résultat de la sélection.

Enfin, de la fusion résulte une information précise, et l'algorithme des k-moyennes donne une binarisation adaptée à la dynamique de l'image de fusion.

La robustesse des résultats provient en fait de l'ensemble de notre procédure.

Un aspect primodial de sa mise en œuvre est l'ordre que nous fixons pour la reconnaissance des objets; cet ordre est le garant de bons résultats. Le fait de commencer par des structures anatomiques de taille importante, et déterminantes du point de vue de l'architecture cérébrale, permet de constituer un acquis. La connaissance de ces structures facilite l'introduction d'informations *a priori* qui décrivent d'autres structures, que nous ne pourrions pas segmenter aussi facilement de façon directe.

Ainsi, l'obtention préliminaire de l'encéphale fournit une bonne initialisation de notre procédure ; les ventricules latéraux conditionnent la recherche des structures de la partie supérieure de l'encéphale, et nous donnent accès aux noyaux de la base. La détermination du quatrième ventricule est alors possible, et la connaissance de l'anatomie cérébrale est précisée dans l'axe inférieur-supérieur ; au final, le troisième ventricule se détermine facilement.

Les résultats que nous obtenons peuvent être améliorés.

Nous n'avons pas, par exemple, introduit d'information de symétrie par rapport au ventricule latéral droit pour reconnaître le ventricule latéral gauche, ni d'information de direction par rapport au noyau caudé droit pour reconnaître le putamen droit. Notons que l'ajout de telles contraintes spatiales ne se justifie que si elles sont suffisamment stables par rapport à la variabilité anatomique. Ici, elles ne se sont pas avérées utiles pour que la reconnaissance aboutisse; néanmoins, pour des images plus difficiles, elles seraient peut-être nécessaires.

Pour éviter le phénomène de sous-segmentation des structures, il faudrait vraisemblablement modifier la méthode de segmentation; l'ouverture morphologique pourrait être alors avantageusement remplacée par une érosion (plus forte qu'actuellement, afin de compenser l'accroissement de la région), suivie d'une reconstruction numérique par dilatation géodésique.

Nous ne garantissons pas non plus que la segmentation de deux structures adjacentes respecte cette indication topologique (le noyau caudé droit, par exemple, ne se love pas tout à fait contre le ventricule latéral droit). Un post-traitement de la segmentation pourrait suffire, ou mieux, nous pourrions imposer cette contrainte sous la forme d'une information supplémentaire.

Il reste enfin à tester la robustesse de notre méthode sur plusieurs images, comme nous l'avons fait pour la segmentation morphologique. En particulier, la faible sensibilité de notre méthode visà-vis des opérateurs de fusion, de la mesure de similarité, de la segmentation finale, et du calcul approximatif du champ de correspondance, reste à confirmer.
# Conclusion

En comparaison avec les méthodes de segmentation par classification (non contextuelle au chapitre 5, contextuelle au chapitre 6) et par morphologie mathématique (chapitre 7), la procédure de reconnaissance que nous proposons dans cette partie donne de bien meilleurs résultats.

Avec notre procédure, les structures cérébrales sont individuellement reconnues. Chaque étape procède à la segmentation d'une structure donnée, contrairement aux approches des parties précédentes, où la segmentation était globale à l'ensemble des structures pour les classifications, et où elle était difficilement particularisable à chaque structure pour les méthodes de morphologie mathématique.

Ces approches distinguaient les trois matières cérébrales principales (le liquide céphalo-rachidien, la substance grise, et la substance blanche), et séparaient les sillons du système ventriculaire, et le cortex des noyaux centraux. Pour cela, nous avions dû introduire une information *a priori*, en l'oc-currence la distance à la surface encéphalique (sections 6.3.2 et 7.3.2).

Malgré les bons résultats obtenus pour de telles approches (figure 6.10 et annexe C), la segmentation était approximative. Une part importante de la citerne quadrijumelle n'était pas dissociée du troisième ventricule, ce dernier n'étant pas toujours séparé des ventricules latéraux. Pour les noyaux, nous n'obtenions véritablement que des marqueurs, leur morphologie étant relativement grossière.

Les informations exploitées dans notre méthode de reconnaissance sont d'une part celles utilisées dans les approches de classification contextuelle et de morphologie mathématique, et d'autre part des informations spatiales entre les structures. Les premières sont utilisées ici conditionnellement à des régions d'intérêt, ce qui les rend plus robustes; les secondes viennent les compléter, puisque nous avions vu qu'elles faisaient défaut dans les approches des parties II et III alors qu'elles avaient une grande importance anatomique (partie I).

Le fait de traiter séquentiellement les structures anatomiques et de s'appuyer sur un modèle se traduit par de nombreux avantages.

Un atlas, utilisé à travers un champ de correspondance (chapitre 11), sert de guide. Par rapport à l'existant (chapitre 9), une originalité de notre procédure réside dans le calcul progressif de ce champ, qui devient de plus en plus précis au cours de la reconnaissance. A chaque nouvel objet identifié dans l'image, le champ est actualisé, contraint par les surfaces des objets reconnus. Un modèle très simple, lui aussi original, peut alors être utilisé pour son calcul (section 11.3); il repose sur une approche discrète et itérative de la résolution d'une équation exprimant que le laplacien vectoriel du champ est nul.

A chaque étape de notre procédure, la segmentation d'une structure est limitée à une région d'intérêt déduite de l'atlas, ce qui rend robuste l'emploi d'une classification automatique (Cf. figure 12.6). De plus, la connaissance des structures déjà reconnues permet l'expression d'informations particulières à la structure recherchée (section 12.2); leur prise en compte augmente la précision de la segmentation, et facilite la reconnaissance. Avec des approches classiques, l'introduction de telles informations serait délicate.

Contrairement à la séquentialité des traitements morphologiques, celle de notre procédure est beaucoup plus robuste; chaque segmentation étant limitée à une région d'intérêt, et donc plus précise, les erreurs qui peuvent survenir à une étape sont mineures, et n'ont qu'une faible incidence sur les étapes suivantes.

Une particularité intéressante de notre procédure est qu'à chaque étape elle emploie la théorie des ensembles flous sur les structures non floues déjà reconnues.

La théorie des ensembles flous offre un cadre très souple à l'expression d'informations imprécises, et permet de repousser la segmentation après que l'ensemble de ces informations ont été fusionnées. Elle permet d'exprimer dans un même formalisme des informations très hétérogène telles que l'appartenance à une classe en fonction de la radiométrie, des relations de distance, de position relative, des informations de localisation. Elle fournit enfin des outils pour fusionner ces informations, qui permettent ensuite de prenddre une décision binaire.

Quant au caractère non flou de la segmentation finale, résultat de cette décision, il est un gage d'efficacité de notre procédure. D'une part, la mise en œuvre fastidieuse de traitements flous à partir d'ensembles flous est évitée. En effet, les dilations floues, les informations de direction, et les informations de distance s'appuient sur les objets binaires déjà reconnus; leur calcul est donc assez rapide. D'autre part, le caractère non flou de la segmentation finale fournit un cadre rigide au calcul du champ de correspondance.

Enfin, notre procédure de reconnaissance doit être considérée comme un schéma directeur pour la reconnaissance, chaque technique qu'elle fait intervenir étant une véritable boîte noire interchangeable, que ce soit le recalage surfacique, le modèle d'extension du champ de correspondance, l'utilisation des informations, ou la segmentation.

Nous n'avons pas poussé plus loin la reconnaissance des structures internes du cerveau, faute de temps, et à cause de l'aspect informatique gourmand de notre méthode<sup>1</sup>. Notre procédure est une proposition prometteuse qui doit encore être validée sur un jeu d'acquisitions variées.

<sup>1.</sup> Une image par résonance magnétique nucléaire tridimensionnelle « pèse » de l'ordre de 4 Mo, si la quantification de la radiométrie est limitée à un codage sur 8 bit, et si le volume est restreint à la boîte englobante de l'encéphale; le champ de correspondance équivalent, qui contient les trois coordonnées du vecteur défini en chaque voxel, est de l'ordre de 48 Mo (sur une machine où un flottant est codé sur 32 bit). L'exigence en mémoire vive, en place disque, et en calcul est donc élevée. Le temps de calcul nécessaire à l'exécution d'une étape de notre procédure sur une station de travail actuelle, sans collaboration de plusieurs microprocesseurs et sans mise en œuvre multi-échelles, est de l'ordre de 5 minutes, soit 30 minutes pour les six structures segmentées ici.

**Conclusion générale** 

Le sujet de notre travail était de segmenter les structures internes du cerveau en imagerie par résonance magnétique tridimensionnelle, ce qui représente un enjeu important pour des études anatomiques comme fonctionnelles. Les difficultés que nous avions à surmonter résident dans la grande variabilité morphologique des structures cérébrales, et dans leur proximité aussi bien au sein du cerveau que dans l'espace radiométrique.

Partant de méthodes de classification non contextuelles, nous avons introduit progressivement des informations spatiales. Cette introduction s'est effectuée tout d'abord avec la notion de voisinage, dans les potentiels de cliques en relaxation markovienne, et dans les éléments structurants en morphologie mathématique. Puis ces informations sont devenues de plus en plus structurelles, avec un potentiel de localisation pour la relaxation markovienne, et avec des conditionnements pour la morphologie mathématique. Si les premières parties de ce manuscrit s'appuient uniquement sur les données de l'IRM, la méthode de reconnaissance que nous proposons dans la dernière partie utilise un modèle anatomique sous la forme d'un atlas, et intègre des informations spatiales structurelles plus complètes.

La première partie a été consacrée à une présentation de l'anatomie cérébrale, et à son observation en imagerie par résonance magnétique tridimensionnelle.

Nous avons décrit les objets cérébraux par quatre types d'informations: leur classe radiométrique, qui dépend de leur matière constitutrice (tissu ou liquide), et les relations spatiales, que sont les relations ensemblistes, directionnelles, et de distance. Si l'ensemble de ces informations est important pour la reconnaissance visuelle que pratiquent les anatomistes, elles sont rarement prises en compte de façon simultanée dans la plupart des méthodes de la littérature. C'est sur cette description des structures, exprimée sous forme d'informations, que repose notre méthode finale de reconnaissance. Une description relationnelle de l'anatomie cérébrale mériterait d'être beaucoup plus précise ; en particulier, elle pourrait s'appuyer sur les parties de structures, plutôt que sur les structures ellesmêmes.

Afin de modéliser les informations radiométriques, nous avons effectué des tests de gaussienneté sur plusieurs structures anatomiques, à partir d'une segmentation manuelle; pour cela, nous avons proposé un protocole qui garantit que ces tests laissent de côté les volumes de mélange, et qu'ils sont donc robustes. Nous avons alors constaté le caractère gaussien des lois radiométriques. Bien que cela soit généralement admis, nous n'avons pas trouvé dans la littérature de réalisation de pareils tests. Nos résultats devraient néanmoins être validés sur une grande quantité d'acquisitions de séquences variées.

La deuxième partie a traité de méthodes de segmentation non contextuelles ; seules les informations radiométriques ont donc été considérées.

Comme nous avons réalisé, au cours de la première partie, un apprentissage manuel des statistiques radiométriques de différents objets anatomiques, nous avons pu juger des limites d'une approche bayésienne paramétrique : le fort recouvrement des lois radiométriques des différents objets ne permet que de distinguer les trois matières cérébrales principales (liquide céphalo-rachidien, substance grise et substance blanche), y compris lorsque nous disposons de deux acquisitions de modalités différentes.

Des outils de classification automatique pouvant s'avérer très utiles, nous avons examiné le comportement de l'algorithme des k-moyennes. Nous avons remis en cause sa fiabilité à donner effectivement des classes proches de l'optimal, au sens de la fonctionnelle à minimiser; nous avons alors proposé une solution empirique destinée à le rendre plus robuste : l'algorithme est répété et sa meilleure solution est conservée. Si les critères de validité de classifications sont généralement définis dans l'espace des caractéristiques, une voie de recherche consisterait ici à exprimer un critère qui tienne compte aussi de la cohérence spatiale des classes dans l'image. Mais il est préférable alors d'introduire des contraintes de cohérence spatiale dans les méthodes elles-mêmes, ce qui fait l'objet des parties suivantes.

La troisième partie s'est intéressée à l'introduction de la notion de contexte en segmentation.

En premier lieu, nous avons examiné l'approche markovienne, méthode assez classique de classification avec régularisation spatiale. Nous avons montré qu'elle définit un cadre formel dans lequel la prise en compte d'informations supplémentaires de localisation peut donner de bons résultats. Ainsi nous avons pu distinguer, au sein de la substance grise, le cortex et les noyaux centraux, ce qui à notre connaissance n'avait jamais été réalisé avec cette méthode. Ces résultats pourraient être améliorés en prenant en compte explicitement l'existence de classes de mélange : les structures anatomiques de morphologie plutôt surfacique (comme les sillons par exemple) ne disparaîtraient pas avec la régularisation, et les ambiguïtés qui existent entre les classes de mélange et d'autres classes de radiométrie proche pourraient être levées grâce à des termes contextuels.

Nous avons aussi mis en œuvre une classification markovienne sur un graphe d'adjacence, construit à partir des bassins versants donnés par l'algorithme de la surface de partage des eaux. L'intérêt d'utiliser une sur-segmentation est de simplifier le traitement des données, tout en conservant l'essentiel des informations qu'elles comportent. Cependant, la classification fournit des résultats trop grossiers parce qu'elle ne porte que sur les bassins versants, les éléments de surface n'étant pas classifiés. A titre de perspective, nous avons alors proposé une méthode de constitution d'un graphe d'adjacence, qui permet l'étiquetage des bassins comme celui des éléments de surface.

Une seconde approche pour introduire la notion de contexte est la morphologie mathématique. Nous avons élaboré dans ce cadre des procédures automatiques de segmentation pour un certain nombre de structures (encéphale, sillons, cortex, système ventriculaire, noyaux centraux, et substance blanche); ces procédures ont été validées sur une base d'images de grande variabilité, vis-à-vis des imageurs, des séquences d'acquisition, et des sujets, sains et pathologiques. La robustesse de nos procédures provient des deux types de paramètres qu'elles utilisent: les paramètres radiométriques, appris automatiquement, et les paramètres morphologiques, déduits de connaissances anatomiques. L'originalité de notre travail réside essentiellement dans l'enchaînement des opérateurs, et dans les conditionnements des différents résultats de segmentation entre eux. Nous avons réussi à distinguer le cortex et les noyaux centraux ; les sillons sont obtenus par une utilisation originale de l'algorithme de la surface de partage des eaux ; et la procédure que nous proposons pour segmenter l'encéphale donne de très bons résultats, robustes et reproductibles.

Enfin, nous présentons une méthode originale qui permet d'évaluer l'évolution des statistiques radiométriques de deux tissus de part et d'autre de leur frontière. Pour cela, nous définissons des zones d'influence entre deux régions. Nous avons montré comment cette méthode pouvait être employée pour donner les statistiques des tissus purs à partir d'une segmentation même grossière. Elle a aussi été mise en œuvre avec succès pour une application de volumétrie de pathologie en imagerie très anisotrope. Puisque cette méthode exprime la notion de contexte spatial d'une structure, elle pourrait également servir d'outil pour l'étude statistique de la modification des lois radiométriques entraînée par l'effet de volume partiel.

La quatrième et dernière partie a été pour nous l'occasion de tirer le meilleur bénéfice des techniques utilisées dans les parties précédentes. Jusqu'ici, nous avons vu que l'apport d'informations descriptives concernant les structures anatomiques donnait de bons résultats, mais que le cadre trop général du traitement de ces informations ne permettait pas d'exploiter les informations particulières à chaque structure. Par exemple, la reconnaissance individuelle de chaque noyau central était possible mais au détriment du respect de leur morphologie.

Nous avons donc proposé une procédure originale de reconnaissance des structures internes cérébrales, qui répond à l'objectif de prendre en compte, pour chaque structure, l'ensemble des connaissances anatomiques dont nous disposons. Les connaissances sont exprimées d'une part sous forme linguistique, comme les relations spatiales par exemple, d'autre part sous forme iconique, via un atlas anatomique. Pour représenter ces connaissances hétérogènes, nous avons choisi le cadre théorique des ensembles flous, et nous avons vu que ses outils permettent non seulement d'exprimer les différents types d'informations dont nous disposons, quelle que soit leur sémantique, mais aussi de réaliser leur fusion pour aboutir finalement à une décision pertinente.

Notre procédure est guidée par un champ de correspondance, défini entre l'atlas et l'image à traiter, et actualisé à chaque nouvelle segmentation d'objet anatomique. A notre connaissance, l'aspect séquentiel de cette approche est original. Il permet d'exploiter l'ensemble des connaissances *a priori* de l'anatomie cérébrale : à chaque étape, la reconnaissance peut s'appuyer sur toute information relative à un objet déjà segmenté. Le modèle que suit le champ de correspondance, discret et de laplacien vectoriel nul, est lui aussi original, et volontairement approximatif. Simple à mettre en œuvre, il est justifié par la structure que nous avons adoptée pour décrire les objets : il est contraint par la déformation de leur surface, et son calcul peut être mené de façon indépendante au sein de chaque région délimitée par ces surfaces. Ce calcul pourrait facilement faire l'objet d'une implantation multi-échelles ; cela permettrait d'obtenir une plus grande précision tout en conservant un temps de calcul raisonnable. Les défauts inhérents au modèle sont dus à l'absence de structure topologique forte : la correspondance ne respecte pas strictement la relation conteneur-contenu, les adjacences entre structures ne sont pas imposées explicitement, il ne tolère pas de glissements dans la position relative de deux structures adjacentes.

A chaque étape de notre procédure, les données radiométriques de l'image sont classifiées automatiquement par l'algorithme des k-moyennes. Pour assurer l'obtention d'une classe qui représente la structure recherchée, plusieurs classifications sont menées avec un nombre de classes variable, et pour que ces classifications soient robustes, elles sont limitées à une région d'intérêt contenant cette structure. La sélection de l'information la plus pertinente issue des classifications est réalisée avec une mesure de similarité avec des informations *a priori*. Au final, l'ensemble des informations qui décrivent la structure recherchée sont fusionnées, et le résultat de la fusion est traité morphologiquement, pour qu'une binarisation contextuelle locale, suivie d'un étiquetage des composantes connexes, fournisse la segmentation désirée. Cette méthode de segmentation est, à notre connaissance, entièrement originale.

Enfin, une part importante de notre contribution a été de construire une bibliothèque de traitements d'images numériques, dans laquelle se retrouvent tous les outils mis en œuvre durant ce travail de thèse. Son originalité principale réside dans le fait que les traitements qu'elle contient fonctionnent aussi bien avec des images tridimensionnelles qu'avec des images bidimensionnelles, et qu'ils prennent en compte l'éventuelle anisotropie des images. Nous avons toutefois un regret : cette bibliothèque ne tire pas profit du paradigme objet. Si cela était le cas, les différentes structures d'images, et les types variés de données qui les constituent, pourraient réutiliser avantageusement les algorithmes de traitements que nous avons mis en œuvre. Comme notre procédure de reconnaissance semble fournir un cadre intéressant à la segmentation des structures internes cérébrales, les perspectives que nous imaginons à notre travail s'articulent autour de cette dernière méthode.

L'atlas utilisé devrait être beaucoup plus détaillé. La définition des structures anatomiques devrait être exhaustive, et devrait distinguer pour chaque structure ses différentes parties. Ces dernières seraient de véritables objets anatomiques à part entière (par exemple, le troisième ventricule serait composé de plusieurs parties discriminées par leur position relative par rapport à l'adhérence interthalamique et au plan inter-hémisphérique). Cela se traduirait par trois avantages importants.

En premier lieu, de la même façon que, par rapport aux premières parties qui traitent de groupes de structures anatomiques, la dernière partie traite chaque structure indépendamment, nous pourrions alors considérer chaque structure comme un ensemble d'objets, et décider de traiter chaque structure particulière par partie. Les relations entre objets cérébraux (sous-structures anatomiques) pourraient être plus précises, et donc les informations concernant les objets recherchés plus nombreuses, et ces objets mieux décrits.

Cela permettrait aussi d'améliorer le recalage surfacique entre les structures de référence et celles qui sont segmentés dans l'image. La surface d'une structure serait composée des éléments de surface de ses parties, et le recalage pourrait s'effectuer simultanément pour ces multiples éléments.

Enfin, du point de vue de la segmentation, elle serait améliorable *a posteriori*. Après l'étape de recalage multiple, nous aurions la possibilité de détecter des défauts dans cette segmentation. Le problème de l'absence de reconnaissance de la partie supérieure du troisième ventricule, que nous avons observé avec notre procédure, pourrait ainsi être identifié, et corrigé.

La sous-étape de segmentation, qui part de la sélection d'une information issue de classifications pour donner un objet binaire, pourrait être remplacée par d'autres techniques de segmentation. En particulier, il serait intéressant de se placer dans un cadre markovien, et ce pour plusieurs raisons.

Nous avons vu que l'apport d'informations de localisation au sein de la relaxation donnait de bons résultats. Ici, ces informations sont multiples, et pourraient être introduites sous la forme de termes énergétiques.

Les informations radiométriques de l'objet recherché et des autres objets présents dans la région d'intérêt floue étant connues plus ou moins approximativement, les paramètres du terme d'attache aux données pourraient dans un premier temps être fixés. Il pourrait en être de même pour les coefficients de la matrice de Potts ; en particulier, ils pourraient favoriser des contraintes d'adjacence par la présence des objets déjà reconnus.

Une autre perspective de notre travail serait d'autoriser dans notre procédure séquentielle des retours en arrière. Cela nécessiterait alors de définir une stratégie de segmentation.

Il nous semble raisonnable qu'il faille fixer l'ordre dans lequel les structures seraient segmentées, et que les retours en arrière ne soient possibles qu'à l'issue de certains groupements d'étapes. Pour que la procédure de reconnaissance reste automatique, un critère de validité devrait aussi être défini, et dépendrait de deux facteurs : la cohérence interne au groupe d'objets qui viennent d'être segmentés, et la cohérence externe de ce groupe vis-à-vis des objets qui ont été segmentés antérieurement. Il nous semble qu'une telle proposition s'accompagnerait bien d'une segmentation floue des objets d'un même groupe. Ainsi, pour juger de la cohérence interne, nous pourrions utiliser une mesure d'intersection ou de distance spatiale.

Si la procédure de reconnaissance que nous proposons pêche par son manque de validation, ses résultats sont très prometteurs, et sa construction est suffisamment ouverte pour qu'elle puisse être reprise et améliorée.

# Annexes

# Annexe A

# Prise en compte de l'anisotropie en traitement d'images 3D

Comme nous l'avons vu en section 2.1.3, les images que nous avons à traiter présentent la particularité d'être généralement anisotropes. De nombreux traitements d'images peuvent se résumer ainsi : pour chaque point de l'image, son examen et celui de son voisinage permettent d'affecter à ce point une nouvelle valeur. Les traitements classiques d'images doivent donc être adaptés pour que la notion de voisinage tienne compte d'une éventuelle anisotropie.

Après avoir défini des notations abrégées, nous proposons pour plusieurs opérateurs classiques de traitement d'images diverses formules qui tiennent compte de l'anisotropie des images.

### A.1 Notations

Soit  $(\Delta x, \Delta y, \Delta z)$  les dimensions des voxels de l'image. Notons, de façon générique, x une des coordonnées d'un voxel de l'image; ce peut être effectivement x, mais aussi y ou z.

notation	signification
$x^+$	$x + \Delta x$
<i>x</i> -	$x \Leftrightarrow \Delta x$
$x^{\oplus}$	$x + \Delta x/2$
$x^{\ominus}$	$x \Leftrightarrow \Delta x/2$
<i>x</i> *	$x \text{ ou } x^+ \text{ ou } x^- \text{ ou } x^\oplus \text{ ou } x^\Theta$

Pour désigner un jeu de coordonnées modifié par rapport à (x, y, z), nous nous permettons de ne pas faire apparaître les coordonnées non modifiées. Ainsi par exemple :

 $\begin{array}{ll} (x^{*}) & \mbox{désigne} & (x^{*},y,z) \\ (x^{*1},z^{*2}) & \mbox{désigne} & (x^{*1},y,z^{*2}). \end{array}$ 

Soit f une fonction des 3 coordonnées (x, y, z). Notons :

notation	signification
$\Delta f(x^{*1}:x^{*2})$	$f(x^{*2}) \Leftrightarrow f(x^{*1})$
$\Delta f(x^*:)$	$\Delta f(x^*:x)$
$\Delta f(:x^*)$	$\Delta f(x:x^*)$
$\Delta f(x \times)$	$\Delta f(x - : x +)$
$\Delta f(x \otimes)$	$\Delta f(x^{\ominus}:x^{\oplus})$

	· · ·	, 1.		1	1		• 1/	1 /	1	
- AC	notatione e	annlia	ment a	chadue	coord	nnee	indene	ndamment	dec	autrec ·
$\mathcal{C}\mathcal{C}\mathcal{O}$	notations s	abbild	iuciii a	Chaque	COOLU		mache	nuannium	ucs	autics.
		··· F F · · ·								

notation	signification
X	$x^{*1}:x^{*2}$
Y	$y^{*3}:y^{*4}$
$\Delta f(X,Y)$	$f(x^{*2}, y^{*4}) \Leftrightarrow f(x^{*1}, y^{*3})$
$\Delta f(X, y^*)$	$f(x^{*2}, y^*) \Leftrightarrow f(x^{*1}, y^*)$

Par exemple :

$$\Delta f(x^{\,\times},y^{\,\ominus},:z^{\,\oplus}) \quad \text{signifie} \quad f(\ x+\Delta x,\ y\Leftrightarrow \frac{\Delta y}{2},\ z+\frac{\Delta z}{2}\ ) \ \Leftrightarrow f(\ x\Leftrightarrow \Delta x,\ y\Leftrightarrow \frac{\Delta y}{2},\ z\ ) \ .$$

## A.2 Gradients

#### A.2.1 Cas bidimensionnel

Considérons le site s = (x, y) de l'image bidimensionnelle I. Le gradient s'écrit :

$$abla I(s) = \left( egin{array}{c} 
abla I_x(s) \\
abla I_y(s) \end{array} 
ight) \quad ext{où} \quad 
abla I_x(s) = rac{\partial I}{\partial x}(s) \ .$$

Le gradient suivant x peut se discrétiser en ce que nous appelerons des «demi-gradients»:

$$\nabla I_x^+(s) = \frac{\Delta I(:x^+)}{\Delta x} ,$$
  

$$\nabla I_x^-(s) = \frac{\Delta I(x^-:)}{\Delta x} .$$

Un gradient moyen entre les deux demi-gradients peut être défini :

$$\nabla I_x^{\times}(s) = \frac{\nabla I_x^+(s) + \nabla I_x^-(s)}{2} = \frac{\Delta I(x^{\times})}{2\Delta x} \,.$$

Le gradient en x de Sobel effectue une moyenne pondérée de gradients moyens, de telle façon que le gradient moyen centré en (s) participe pour moitié au gradient total, et que les gradients moyens excentrés suivant y (c'est-'a-dire en  $(x, y^+)$  et en  $(x, y^-)$ ) aient le même poids. Ainsi :

$$\begin{aligned} \nabla I_x^{\text{Sobel}}(s) &= \frac{1}{2} \nabla I_x^{\times}(y) + \frac{1}{4} \nabla I_x^{\times}(y^+) + \frac{1}{4} \nabla I_x^{\times}(y^-) \\ &= \frac{\frac{1}{2} \Delta I(x^{\times}) + \frac{1}{4} (\Delta I(x^{\times}, y^+) + \Delta I(x^{\times}, y^-))}{2 \, \Delta x} \,. \end{aligned}$$

Le gradient en x de Sobel peut s'écrire sous la forme d'une convolution de noyau  $S_x$ :

$$\nabla I_x^{\text{Sobel}}(s) = I * S_x(s) \; ,$$

où :

$$S_x(s) = \frac{1}{8\Delta x} \frac{\begin{array}{c} 1 & 0 & \Leftrightarrow 1 \\ 2 & 0 & \Leftrightarrow 2 \\ \hline 1 & 0 & \Leftrightarrow 1 \end{array},$$

les colonnes de gauche à droite correspondant respectivement à  $x = \Leftrightarrow \Delta x, 0, \Delta x$ , et les lignes de haut en bas à  $y = \Leftrightarrow \Delta y, 0, \Delta y$ .

#### A.2.2 Cas tridimensionnel

Pour le cas tridimensionnel, les trois premiers gradients conservent leur écriture.

En revanche, le gradient de Sobel doit être adapté. La contribution en (s) doit avoir une pondération similaire à celle de l'ensemble des quatre autres contributions calculées en  $(y^-)$ ,  $(y^+)$ ,  $(z^-)$  et  $(z^+)$ . Nous pouvons écrire :

$$\nabla I_x^{\text{Sobel}}(s) = \frac{1}{2} \nabla I_x^{\times}(s) + \frac{1}{2} \left\{ \alpha_{xy} \left( \frac{\nabla I_x^{\times}(y^+) + \nabla I_x^{\times}(y^-)}{2} \right) + \alpha_{xz} \left( \frac{\nabla I_x^{\times}(z^+) + \nabla I_x^{\times}(z^-)}{2} \right) \right\} ,$$

où  $\alpha_{xy}$  et  $\alpha_{xz}$  sont des constantes dont la somme vaut 1 et qui ne sont pas *a priori* égales car la pondération doit être plus importante pour les gradients voisins les plus proches. Nous avons choisi de prendre une pondération inversement proportionnelle à la distance :

$$\begin{pmatrix} \alpha_{xy} + \alpha_{xz} &= 1 \\ \alpha_{xy} &= \alpha_x / \Delta y \\ \alpha_{xz} &= \alpha_x / \Delta z \end{pmatrix} \Rightarrow \quad \alpha_x = \frac{\Delta y \Delta z}{\Delta y + \Delta z}$$

Il vient:

$$\nabla I_x^{\text{Sobel}}(s) = \frac{\frac{1}{2}\Delta I(x^{\times}) + \frac{\Delta y \Delta z}{4(\Delta y + \Delta z)} \left(\frac{\Delta I(x^{\times}, y^+) + \Delta I(x^{\times}, y^-)}{\Delta y} + \frac{\Delta I(x^{\times}, z^+) + \Delta I(x^{\times}, z^-)}{\Delta z}\right)}{2\Delta x}$$

les formules  $\nabla I_y^{\rm Sobel}(s)$  et  $\nabla I_z^{\rm Sobel}(s)$  étant écrites de façon similaire.

Le noyau de convolution du gradient en x de Sobel devient donc en 3D :

	0	0	0
	$\frac{\Delta y}{\Delta y + \Delta z}$	0	$\Leftrightarrow \frac{\Delta y}{\Delta y + \Delta z}$
	0	0	0
1	$\frac{\Delta z}{\Delta y + \Delta z}$	0	$\Leftrightarrow \frac{\Delta z}{\Delta y + \Delta z}$
$S_x(s) = \frac{1}{8 \Lambda x}$	2	0	⇔2
$\delta \Delta x$	$\frac{\Delta z}{\Delta y + \Delta z}$	0	$\Leftrightarrow \frac{\Delta z}{\Delta y + \Delta z}$
	0	0	0

où les matrices de haut en bas correspondant à  $z = \Leftrightarrow \Delta z, 0, \Delta z$ . Remarquons que nous pouvons retrouver le noyau du cas bidimensionnel en passant à la limite  $\Delta z \to +\infty$ .

 $\frac{y+z}{0}$ 

0

0

0

### A.3 Laplacien

Discrétisons la dérivée seconde par rapport à x en (s) à partir des demi-gradients :

$$\nabla_x^2 I(s) = \nabla_x^+ (\nabla I_x^-(s))$$
  
=  $\nabla_x^+ \left(\frac{\Delta I(x^-:)}{\Delta x}\right)$   
=  $\frac{\Delta I(:x^+) \Leftrightarrow \Delta I(x^-:)}{\Delta x^2}$   
=  $\frac{I(x^+) \Leftrightarrow 2I(s) + I(x^-)}{\Delta x^2}$ .

Remarquons que cette formule peut également s'obtenir avec :

$$\nabla^2_x I(s) = \nabla^{\otimes}_x (\nabla I^{\otimes}_x(s)) \quad \text{où} \quad \nabla I^{\otimes}_x(s) = \frac{\Delta I(x^{\otimes})}{\Delta x} \; .$$

De l'écriture de la dérivée seconde, nous déduisons celle du laplacien :

$$\begin{aligned} \Delta I(s) &= \nabla_x^2 I(s) + \nabla_y^2 I(s) + \nabla_z^2 I(s) \\ &= \frac{I(x^+) + I(x^-)}{\Delta x^2} + \frac{I(y^+) + I(y^-)}{\Delta y^2} + \frac{I(z^+) + I(z^-)}{\Delta z^2} \Leftrightarrow 2\left(\frac{1}{\Delta x^2} + \frac{1}{\Delta y^2} + \frac{1}{\Delta z^2}\right) I(s) \;. \end{aligned}$$

Il s'exprime donc sous la forme d'une convolution dont le noyau est :



U	U	U
0	$\frac{1}{\Delta z^2}$	0
0	0	0

# A.4 Diffusion

L'équation de la diffusion s'écrit :

$$\frac{\partial I}{\partial t}(s,t) = \operatorname{div}(c(s,t)\nabla I(s,t))$$

Discrétisons le terme en x de la divergence :

$$\begin{split} \frac{\partial}{\partial x} \left[ c(x,t) \frac{\partial I}{\partial x}(x,t) \right] &= \frac{c(x^{\oplus},t) \Delta I(:x^{+},t) + c(x^{\oplus},t) \Delta I(:x^{-},t)}{\Delta x^{2}} \,. \\ \frac{\partial}{\partial x} \left[ c(s,t) \frac{\partial I}{\partial x}(s,t) \right] &= \frac{\partial}{\partial x} \left[ c(x,t) \frac{\Delta I_{x}^{\otimes}(s)}{\Delta x} \right] \\ &= \frac{c(x^{\oplus},t) \Delta I(:x^{+},t) \Leftrightarrow c(x^{\oplus},t) \Delta I(x^{-}:,t)}{\Delta x^{2}} \end{split}$$

$$= \frac{\Delta x^2}{\Delta x^2} - \frac{\frac{\Delta x^2}{x^2}}{\frac{\Delta x^2}{\Delta x^2}} \cdot \frac{\frac{\Delta x^2}{x^2}}{\frac{\Delta x^2}{x^2}} \cdot \frac{\frac{\Delta x^2}{x^2}}{\frac{\Delta x^2}{x^2}}$$

En définissant les flux suivant:

$$\begin{split} \phi_{x^{\oplus}} &= c(x^{\oplus},t)\Delta I(:x^{+},t) / \Delta x^{2} \\ \phi_{x^{\oplus}} &= c(x^{\oplus},t)\Delta I(:x^{-},t) / \Delta x^{2} , \end{split}$$

la diffusion s'écrit alors :

$$I(s,t^{+}) = I(s,t) + \Delta t \left( \phi_{x^{\oplus}} + \phi_{x^{\ominus}} + \phi_{y^{\oplus}} + \phi_{y^{\ominus}} + \phi_{z^{\oplus}} + \phi_{z^{\ominus}} \right).$$

Les coefficients de diffusion c entre deux voxels s'expriment avec une fonction (notée f) du gradient correspondant, soit :

$$\begin{array}{lll} c(x^{\oplus},t) &=& f(|\nabla I(x^{\oplus},t)|) \ , \\ c(x^{\ominus},t) &=& f(|\nabla I(x^{\ominus},t)|) \ , \end{array}$$

où nous pouvons effectuer comme approximation:

$$\nabla I(x^{\oplus}, t) = \frac{\Delta I(:x^+, t)}{\Delta x} ,$$
  

$$\nabla I(x^{\ominus}, t) = \frac{\Delta I(:x^-, t)}{\Delta x} .$$

Il en est de même pour les coefficients en y et z.

## A.5 Cartes de distances

Pour le calcul de cartes de distances (chapitre 7), nous utilisons une méthode de propagation par chanfrein [BORG-86, VERW-91, MULL-92]. Les poids affectés aux voxels du masque de chanfrein prennent en compte l'anisotropie éventuelle de l'image. Ces poids ont des valeurs entières afin que le calcul de la carte soit plus rapide ; à l'issue du calcul, un voxel de la carte de distance (à valeur entière) est approximativement proportionnel à la distance euclidienne. Pour obtenir des distances en millimètres, il suffit donc d'appliquer un coefficient multiplicatif.

# Annexe B

# **Relaxation markovienne**

Pour réaliser une classification markovienne, nous devons minimiser une somme énergétique de deux termes, donnée par la formule (6.10) page 121. Le premier terme représente l'attache aux données en un site *s* tandis que le second, contextuel, représente des contraintes appliquées au sein de la classification dans le voisinage de *s*. Nous sommes donc confrontés à un problème d'optimisation globale.

Cette annexe présente les outils algorithmiques qui nous permettent de mener à bien cette optimisation (sections B.1 et B.2), discute les problèmes de leur mise en œuvre, et propose des solutions (section B.3) qui ont été utilisées pour établir les résultats du chapitre 6.

### **B.1** Schéma général des optimisations markoviennes

Les méthodes d'optimisation globale du problème exprimé par un champ de Markov procèdent d'un même schéma :

- **s1.** on se donne une réalisation initiale;
- s2. un site est choisi de façon stochastique;
- s3. ce site peut se voir affecter un nouvel état (une nouvelle classe);
- s4. si un critère d'arrêt n'est pas vérifié, on retourne à l'étape s2, sinon on retient comme résultat final la dernière réalisation obtenue.

Le problème étant global, rien ne peut garantir qu'une réalisation optimale a été découverte avant que l'ensemble des réalisations possibles n'a été passé en revue ; la cardinalité de cet ensemble étant  $c^n$ , avec c nombre de classes et n nombre de sites, son exploration n'est pas envisageable. En revanche, il est possible de tirer parti d'algorithmes d'optimisation globale qui convergent, sous un certain nombre de contraintes théoriques, vers une réalisation optimale. Plusieurs remarques s'imposent :

 L'introduction d'un critère d'arrêt est nécessaire pour mettre un terme à la procédure de convergence; aussi, les résultats finals se limitent généralement à une approximation d'un résultat optimal. Une qualité essentielle d'une mise en œuvre algorithmique consiste donc à garantir que la réalisation qu'elle fournit s'approche le plus possible de la réalisation que l'on attend.

– Pour un même problème, plusieurs réalisations optimales peuvent coexister, et si tel est le cas, la réalisation optimale particulière vers laquelle un algorithme converge dépend à la fois de la réalisation initiale (étape s1) et des tirages stochastiques (étapes s2 et s3). Montrons maintenant que, malheureusement, ces facteurs aléatoires peuvent jouer un rôle important.

Définir complètement la forme des énergies de l'équation (6.10) avant l'optimisation fixe l'aspect du paysage énergétique dans lequel un minimum optimal est recherché. Si le paysage est trop accidenté et ne présente pas par endroit de dénivelé significatif, la procédure risque de se terminer sur une réalisation très sous-optimale, éloignée de la réalisation attendue; ce risque n'est pas contrôlable et dépend des facteurs aléatoires précités.

Garantir une réalisation quasi-optimale nécessite que le paysage ne soit pas trop chaotique et comporte une vallée dont la profondeur la démarque des autres ; les facteurs aléatoires sont alors limités. La maîtrise de la forme des énergies est donc essentielle pour la bonne réalisation de l'optimisation.

 Les algorithmes permettant de résoudre les problèmes d'optimisation globale sont des méthodes stochastiques de relaxation. Ils correspondent au schéma général donné précédemment et se distinguent uniquement par la façon dont ils mettent en œuvre l'étape s3.

Leur algorithmie est donc *a priori* indépendante du choix du type de balayage et du critère d'arrêt. Cependant, leur comportement particulier ne permet pas d'effectuer n'importe quel choix si l'on souhaite rendre l'optimisation performante.

Nous détaillerons par la suite les différents points que nous venons de mentionner.

## **B.2** Algorithmes d'optimisation

Présentons maintenant trois algorithmes d'optimisation par relaxation, qui s'appliquent à l'affectation éventuelle d'un nouvel état à un site (étape **s3** du schéma général).

Les deux premiers, l'échantillonneur de Gibbs et l'algorithme de Métropolis, sont stochastiques : la minimisation de l'énergie en chaque site est favorisée mais non systématique et un facteur aléatoire intervient.

Le troisième algorithme, celui des modes conditionnels itérés, est quant à lui déterministe : l'énergie ne fait que décroître et ce, le plus fortement possible ; c'est une descente classique.

#### B.2.1 Échantillonneur de Gibbs

L'échantillonneur de Gibbs est une méthode stochastique de relaxation où l'on fixe l'état (la classe) d'un site suivant les probabilités locales. Son fondement mathématique est prouvé en [BESA-74] et [GEMA-84]. Il peut se résumer ainsi:

Pour un site s considéré,

**e1.** calculer pour tout état possible  $\omega_i$   $(i \in 1...c)$  du site sa probabilité  $P_i$ ,

e2. effectuer un tirage aléatoire suivant cette loi de probabilité,

e3. affecter au site ce nouvel état.

L'utilisation de la loi fondée sur les probabilités locales permet de favoriser une modification de l'état de chaque site afin que son énergie locale soit faible. La tendance est donc à la minimisation de l'énergie en tout site mais n'exclut pas les sauts positifs d'énergie locale qui permettent parfois, immédiatement ou ultérieurement, une baisse de l'énergie globale.

À l'étape **e1**,  $P_i$  est calculée en appliquant la formule (6.11) page 122 :

$$P_{i} = P(y_{s} = y_{s}^{(t+1)}, y_{s}^{(t+1)} \in \omega_{i} \mid X, Y^{(t)} \Leftrightarrow \{y_{s}^{(t)}\})$$

L'étape e2 s'effectue à l'aide d'une fonction de répartition F définie telle que :

$$F(i) = \sum_{j=1}^{i} P_j \quad \forall i \ge 1 .$$

[0,1[ est partitionné en c intervalles tels que le  $i^{\text{ème}}$  soit de longueur égale à la probabilité  $P_i$ ; à chaque intervalle correspond donc une classe :

état 
$$\omega_1 \quad \Leftrightarrow [0, F(1)]$$
  
état  $\omega_i$  avec  $i \ge 2 \quad \Leftrightarrow [F(i \Leftrightarrow 1), F(i)]$ .

Effectuer un tirage suivant une loi uniforme entre 0 et 1 désigne un intervalle donc un état; au final, la loi de tirage aléatoire d'un état est conforme à la loi définie par les  $P_i$ .

#### **B.2.2 Métropolis**

L'algorithme de Métropolis [METR-53] est une méthode stochastique de relaxation différente de l'échantillonneur de Gibbs en ceci qu'elle ne nécessite pas le calcul de l'ensemble des probabilités locales (étape **e1**).

Pour un site s considéré,

- m1. tirer selon une loi uniforme un état,
- **m2.** calculer la différence énergétique  $\Delta U$  produite par l'affectation éventuelle du site à ce nouvel état,
- m3. procéder effectivement à l'affectation si la différence est négative, ou, suivant la loi de probabilité induite par le saut énergétique si la différence est positive.

Si  $\Delta U > 0$ , l'étape **m3** procède à un tirage uniforme entre 0 et 1 qui fournit une valeur  $P^{tirage}$ , puis affecte au site s l'état  $\omega_i$  lorsqu'est vérifiée l'inégalité :

$$P^{tirage} < e^{-\Delta U} . \tag{B.1}$$

Remarquons qu'ainsi, l'augmentation de l'énergie locale en un site est d'autant plus probable qu'elle est faible.

Afin de mieux comprendre cette loi probabiliste, explicitons-la à l'aide des probabilités locales. Soit  $\omega_i$  l'état obtenu aléatoirement à l'étape 1; le calcul de la différence énergétique  $\Delta U$  lors de l'étape 2 s'effectue à partir de la formule (6.11) suivant :

$$\Delta U = \Leftrightarrow \log P(y_s = y_s^{(t+1)}, y_s^{(t+1)} \in \omega_i | \mathcal{X} = X, \mathcal{Y} \Leftrightarrow \{y_s\} = Y^{(t)} \Leftrightarrow \{y_s^{(t)}\})$$
  
+ log  $P(y_s = y_s^{(t+1)}, y_s^{(t+1)} = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} \Leftrightarrow \{y_s\} = Y^{(t)} \Leftrightarrow \{y_s^{(t)}\})$ 

La condition d'affectation (B.1) se traduit finalement par le rapport des probabilités locales :

$$P^{tirage} < \frac{P(y_s = y_s^{(t+1)}, y_s^{(t+1)} \in \omega_i | \mathcal{X} = X, \mathcal{Y} \Leftrightarrow \{y_s\} = Y^{(t)} \Leftrightarrow \{y_s^{(t)}\})}{P(y_s = y_s^{(t+1)}, y_s^{(t+1)} = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} \Leftrightarrow \{y_s\} = Y^{(t)} \Leftrightarrow \{y_s^{(t)}\})}.$$
 (B.2)

Signalons une modification de l'étape 3 de cet algorithme, suggérée dans [KATO-92] : si la différence énergétique est positive, l'affectation suit une loi de probabilité indépendante du saut énergétique :

 $P^{tirage} < P^{seuil}$ 

où  $P^{seuil}$  est un paramètre fixé par l'utilisateur et qui reste constant lors de l'optimisation.

Une variante à histogramme constant de l'algorithme de Métropolis, appelée méthode d'échange [BIND-86] (ou *spin flip* en physique statistique), est particulièrement adaptée aux cas où la proportion (probabilité *a priori*) de chaque classe est connue. Elle procède comme suit :

Pour un site s considéré,

- h1. tirer suivant une loi uniforme un état puis choisir aléatoirement un site s' parmi ceux qui sont dans cet état,
- h2. calculer la différence énergétique produite par l'échange éventuel de l'état des sites s et s',
- **h3.** procéder effectivement à l'échange si la différence est négative, ou suivant la loi de probabilité induite par le saut énergétique, si la différence est positive.

La condition d'affectation (B.2) a maintenant la forme :

$$\begin{split} P^{tirage} < & \frac{P(y_s = y_s^{(t+1)}, y_s^{(t+1)} = y_{s'}^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\})}{P(y_s = y_s^{(t+1)}, y_s^{(t+1)} = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\})} \\ \times \frac{P(y_s = y_{s'}^{(t+1)}, y_{s'}^{(t+1)} = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\})}{P(y_s = y_{s'}^{(t+1)}, y_{s'}^{(t+1)} = y_{s'}^{(t)} | \mathcal{X} = X, \mathcal{Y} - \{y_s\} = Y^{(t)} - \{y_s^{(t)}\})} \end{split}$$

#### **B.2.3** Modes conditionnels itérés

Il est intéressant d'opposer aux méthodes stochastiques de relaxation que nous venons de présenter, une méthode déterministe : l'algorithme des modes conditionnels itérés [BESA-86]. Naturellement, comme toute méthode de descente, elle fournit un résultat correspondant à un minimum local du paysage énergétique, et non au minimum global comme les méthodes stochastiques. Nonobstant, elle peut parfois s'avérer indispensable, le nombre d'itérations qu'elle requiert étant faible. Son algorithmie est à rapprocher de celle de l'échantillonneur de Gibbs :

Pour chaque itération et pour chaque site,

- **i1.** calculer pour tout état possible du site sa probabilité  $P_i$ ,
- i2. affecter au site l'état de probabilité maximale.

Le tirage aléatoire de l'échantillonneur de Gibbs (étape e2) est supprimé pour prendre systématiquement la probabilité locale maximale. Le problème étant global (il ne suffit pas de minimiser l'énergie locale de chaque site pour que l'énergie globale soit minimale), une suite d'itérations est nécessaire à la convergence.

La mise en œuvre de cette méthode est raisonnable dans deux cas de figure : lorsque l'on dispose d'une classification proche de la classification optimale et que l'on souhaite s'en rapprocher davantage ; ou lorsque le paysage énergétique bâti sur l'ensemble des réalisations ne présente des minima locaux qu'aux alentours d'une réalisation optimale.

#### B.2.4 Addition d'un recuit simulé

En pratique, un très grand nombre d'itérations est insuffisant pour s'assurer de l'obtention d'un résultat correct lorsqu'un algorithme stochastique est utilisé. L'introduction d'un recuit simulé [VANL-87], solution classique aux problèmes d'optimisation combinatoire, est alors indispensable.

En effet, même si l'obtention d'un optimum nécessite encore en théorie un nombre infini d'itérations, la convergence est beaucoup plus rapide. Un critère d'arrêt peut alors interrompre le recuit (étape **s4**) après un nombre réduit d'itérations, garantissant que la réalisation finale est relativement proche d'une réalisation optimale.

#### Le principe

Recuire consiste à chauffer fortement puis à contrôler l'abaissement de température de façon à ne pas rester dans les états d'énergie minimaux trop localement. Concrètement, cela se traduit par l'introduction de la température T dans la relation (6.11) entre l'énergie locale en un site et sa probabilité locale associée, suivant :

$$P(y_s = y_s^{(t)} | \mathcal{X} = X, \mathcal{Y} \Leftrightarrow \{y_s\} = Y^{(t)} \Leftrightarrow \{y_s^{(t)}\}) = \frac{1}{Z_s^{(t)}} exp\left( \Leftrightarrow \frac{U^a(x_s^I, y_s^{(t)}) + U_s(Y_{V_s}^{(t)})}{T(t)} \right).$$
(B.3)

où  $t \to T(t)$  est une fonction de décroissance lente.

Au début de la procédure, lorsque la température est élevée, les écarts entre les probabilités locales associées aux différents états sont réduits; les changements d'états brutaux et donc les sauts énergétiques positifs importants sont tolérés. Nous sommes dans une situation de chaos.

Puis, lorsque la température décroît, cette tolérance se réduit et une certaine organisation s'installe progressivement, guidée par la quête d'une énergie minimale.

À la fin de la procédure, la température se rapproche du zéro absolu. En chaque site, la probabilité locale la plus forte associée à un état particulier domine les autres : le comportement de la convergence se rapproche de celui d'une descente et les sauts énergétiques positifs se font rares ; la situation se fige.

Les algorithmes stochastiques de l'échantillonneur de Gibbs et de Métropolis, tels qu'ils ont été présentés en début de section (pages 332 et 333), correspondent à une température constante de 1. L'algorithme déterministe des modes conditionnels itérés est en fait un échantillonneur de Gibbs à température 0.

#### Modification des algorithmes stochastiques

À l'étape **e1** de l'échantillonneur de Gibbs, l'introduction du recuit produit des valeurs différentes des probabilités locales  $P_i$ ; la loi de probabilité de l'étape **e2** en est donc affectée.

Quant à l'algorithme de Métropolis, l'interprétation probabiliste (B.2) reste inchangée. En y reportant l'expression (B.3) des probabilités locale, la condition d'affectation (B.1) devient :

$$P^{tirage} < e^{-\frac{\Delta U}{T(t)}}$$

Ainsi, seule l'étape **m3** est touchée par l'introduction du recuit.

Le comportement de l'algorithme des modes conditionnels itérés est celui d'une descente ; il est donc insensible au recuit. L'explication en est simple : la température atténue ou accentue le rapport

de force entre les probabilités locales mais ne modifie pas leur classement par ordre de valeur ; aussi, la probabilité maximale avec ou sans recuit correspond toujours à la même classe.

### **B.3** Problèmes de mise en œuvre

Afin de mettre en œuvre une optimisation, un certain nombre de précautions doivent être prises afin d'éviter des trappes algorithmiques; elles font l'objet de cette section.

#### **B.3.1** Balayage des sites

Si l'étape **s3** du schéma général (section B.1) constitue le cœur de l'algorithmie d'optimisation dont nous avons présenté diverses formes (section B.2), la façon de choisir un site lors de l'étape **s2** détermine le mode de balayage des sites et conditionne le bon fonctionnement de la convergence.

En théorie ce balayage doit être infini pour que la réalisation correspondant à l'optimum global recherché soit trouvée; une des raisons imposant cette contrainte est que chaque site doit être visité une infinité de fois. Comme ce n'est pas réalisable d'un point de vue pratique<sup>1</sup>, nous devons seulement nous assurer que chaque site est effectivement examiné un grand nombre de fois.

Lorsque l'on a recours à un balayage aléatoire, la satisfaction de cette contrainte nous conduit à choisir un tirage régi par une loi uniforme et mené sur l'ensemble des sites. Cependant, plus la relaxation est limitée à un nombre faible d'itérations, plus le risque que des sites soient peu pris en considération augmente. En particulier, la convergence de l'algorithme des modes conditionnels itérés (déterministe!) est considérablement ralentie par le caractère stochastique du balayage tandis qu'elle ne nécessite qu'une poignée d'itérations sur l'ensemble des sites dans le cadre d'un balayage déterministe.

D'un autre côté, les balayages déterministes couramment usités sont à l'origine d'un biais venant troubler la bonne marche de la relaxation. Nous proposons ici, pour limiter ce biais, une procédure déterministe originale. Un tour est l'ensemble des examens successifs de chaque site du graphe. Classiquement, l'ordre d'examen est inchangé d'un tour à l'autre; pire, il suit souvent l'ordre de stockage des sites en mémoire informatique et donc leur agencement topologique.

Nous proposons ici qu'il soit guidé par les règles énoncées ci-après.

- Une permutation circulaire p est choisie en fonction du nombre de sites de telle façon que son idempotence soit élevée.
- Au premier tour, les sites sont passés en revue en suivant la séquence résultant de l'application de p à une séquence quelconque des sites.
- À un tour donné, la séquence des sites est fournie par la permutation circulaire p appliquée à la séquence des sites utilisée au tour précédent.

L'emploi récursif d'une permutation permet d'éviter de parcourir toujours dans le même ordre les sites lors des tours tout en garantissant que chaque site soit visité un même nombre de fois ; de plus, la permutation rallonge la cyclicité des tirages aléatoires.

De plus, la mise en œuvre informatique de ce balayage est simple. Elle ne nécessite que trois tables de taille n (le nombre de sites) et bijectives sur  $\mathbb{N} \cap [1, n]$ : P, pour stocker la permutation et,  $I_1$  et  $I_2$ , pour stocker les indirections successives. L'initialisation consiste en l'affectation  $I_2 = Id$  (l'identité) puis, avant chaque tour, nous formons  $I_1 = P(I_2)$  ou  $I_2 = P(I_1)$  si le nombre de tours

<sup>1.</sup> En tout cas, dans la limite impartie par la durée d'une thèse.

effectués est respectivement impair ou pair, et nous utilisons la table I qui vient d'être mise à jour (respectivement  $I_1$  ou  $I_2$ ) pour passer les sites en revue : pour i de 1 à n, le site à considérer est  $s_{I[i]}$ .

#### **B.3.2** Tirages aléatoires

Lors de l'étape d'affectation éventuelle d'un nouvel état à un site, les méthodes stochastiques nécessitent des tirages aléatoires. Ces derniers sont offerts en routine par toute plateforme informatique moderne et, d'après leur documentation, suivent une loi uniforme.

Notons toutefois que les algorithmes mis en œuvre sont légèrement biaisés. Des algorithmes corrigeant ce défaut sont en libre service sur le réseau mondial mais ne sont véritablement indispensables que pour des personnes qui ont besoin de tirages très fins, ce qui n'est pas notre cas.

En revanche, un défaut important de ces tirages est leur très grande lenteur. Dans un problème de relaxation où ils sont très sollicités, ils deviennent alors le facteur majeur de lenteur. Une solution couramment employée est d'effectuer un ensemble de pré-tirages mais elle comporte un inconvénient majeur avec tout balayage déterministe : la cyclicité des tirages en chaque site au cours des tours induit un biais important dans la procédure de convergence (Cf. figure B.1). Les résultats peuvent en être complètement faussés, surtout lorsque l'optimum est difficile à atteindre parce que le paysage énergétique est chaotique. Si le traiteur d'images se contente de visualiser le résultat de la classification markovienne, ce biais n'est pas apparent ; il est masqué en partie par l'attache aux données que présente le résultat.

Pour réduire ce biais il suffit que l'ensemble des tirages ait pour cardinalité un nombre premier (999 983 donne une table de flottants de taille de stockage d'environ 32 Mo). De plus, il est préférable que cette cardinalité soit élevée, non seulement pour diminuer encore le biais, mais aussi pour que cet ensemble respecte la loi statistique désirée. Enfin, l'utilisation du balayage pseudo-déterministe que nous avons proposé atténue le biais, puisqu'en mélangeant la séquence de visite des sites, il rallonge l'apparition de la cyclicité des tirages en tout site.

#### **B.3.3** Critère d'arrêt

L'arrêt des tours, lors de l'exécution de l'algorithme de Métropolis ou de l'échantillonneur de Gibbs, pourrait se produire lorsqu'un tour ne modifie aucun état des sites. Cependant, cette heuristique n'est pas très pertinente. En effet, même lorsque la température est extrêmement basse, des changements d'états ont encore lieu; et c'est d'autant plus probable que le nombre de sites est élevé (nous sommes dans ce cas de figure puisque nos images comportent classiquement de l'ordre de plusieurs millions de voxels).

Nous avons donc choisi un test positif d'arrêt de la relaxation lorsque le taux de changements observés lors d'un tour est inférieur à 1/10000. Cette valeur, que nous avons fixée empiriquement, s'est avérée très raisonnable : la relaxation est arrêtée lorsque le champ est déjà très stable, donc en phase terminale. Cette valeur peut paraître très faible, mais il faut rappeller que si l'image comporte huit millions de voxels, le critère d'arrêt porte alors sur l'étiquetage de 800 voxels ; pour évaluer cette quantité dans des acquisitions classiques en  $T_1$ , citons les exemples du ventricule latéral et de la commissure antérieure, dont les ordres de grandeur respectifs du nombre de voxels sont de 5500 et de 150 voxels. La cardinalité en voxels du critère d'arrêt, sachant que ces voxels seront répartis sur l'ensemble de l'image, est donc raisonnablement faible.

Au final, l'algorithme des modes conditionnels itérés peut être utilisé afin de garantir que le résultat final est effectivement un minimum énergétique. Insistons sur le fait que ce minimum est peut-être local mais qu'avec toutes les précautions que nous avons prises, il est proche de l'optimum recherché.



FIG. B.1 – Centième étape d'un recuit biaisé.

Quatre recuits utilisant un balayage séquentiel des points sont menés sur l'image *lena* de façon identique à un unique détail près, la table de nombres aléatoires utilisée est de taille différente : 97 pour (a), 8 191 pour (b), 69 991 pour (c) et 999 983 pour (d) ; ces tailles correspondent environ à respectivement 0,04%, 3%, 27% et 381% du nombre de points de l'image. La convergence est biaisée par l'apparition de motifs (les images de cette figure sont issues de la centième étape de chaque recuit), de moins en moins prononcés lorsque la taille de la table aléatoire croît.

Enfin notons que le nombre de tours nécessaire à la relaxation croît généralement avec le nombre de sites car l'optimisation résulte d'une combinatoire globale.

# Annexe C

# **Résultats de segmentation morphologique**

Cette annexe présente des résultats obtenus par les méthodes morphologiques de la partie III sur des images sélectionnées dans le cadre d'un projet financé par le GIS Sciences de la Cognition, intitulé *Applications des méthodes de traitement d'image à l'étude de l'anatomie tridimensionnelle du cerveau en tant que support aux études fonctionnelles*. Les éléments de description du projet et des images de référence sont tirés du rapport d'avancement de ce projet.

## C.1 Le projet GIS

#### C.1.1 Le cadre du projet

Ce projet d'imagerie cérébrale a été soumis par le **projet Imagerie Cérébrale du GDR-PRC ISIS**. Il s'agit d'une collaboration de type réseau national regroupant à la fois des équipes de traitement d'images et des équipes d'imagerie fonctionnelle et de neurosciences :

- 1. Equipes « traitement d'images »:
  - Département Images de l'ENST (URA 820), Paris (I. Bloch) (coordination du projet),
  - U66 INSERM, Paris (H. Benali),
  - CEA-SHFJ, Orsay (V. Frouin, J.-F. Mangin),
  - GREYC URA1526, Caen (M. Revenu, M. Desvignes),
  - Cyceron, Caen (J.M. Travere),
  - SIM, Rennes (B. Gibaud, C. Barillot),
  - TIMC IMAG, Grenoble (S. Lavallée, E. Bittar),
  - Projet Epidaure, INRIA, Sophia-Antipolis (G. Malandain).
- 2. Equipes « imagerie fonctionnelle et neurosciences » :
  - Laboratoire Signaux et Processus Cérébraux, INSERM U280, Lyon (J. Pernier, O. Bertrand),
  - LENA, URA654, Paris (B. Renault, L. Garnero),
  - CIERM et CJF INSERM CREARE, Paris (Y. Burnod).

3. Ingénieurs de Recherches : Jean-Luc Anton, Tonny Riyanto.

Ce projet vise à poser les bases d'un logiciel de segmentation et d'interprétation d'images anatomiques IRM du cerveau pour servir de support aux études fonctionnelles. Les principaux objectifs du projet sont :

- de déterminer avec précision quels sont les besoins en segmentation selon les diverses utilisations pour l'imagerie fonctionnelle, et les contraintes qui en découlent et que doivent satisfaire les méthodes et les algorithmes,
- de faire le bilan des travaux et outils existants, à la fois au sein des équipes participantes et dans la littérature,
- de définir des critères d'évaluation des méthodes,
- d'élaborer une base de données commune d'images IRM acquises dans diverses conditions, afin de tester les méthodes et de les comparer,
- de diffuser les méthodes développées dans chaque laboratoire.
- de faire naître des collaborations entre les méthodes existantes, de les faire évoluer en fontion des contraintes, de poursuivre leur développement dans ce sens, et de les évaluer sur la base de données.

#### C.1.2 Les images

La base de données constituée dans le cadre de ce projet contient des images de différents types, acquises sur des machines différentes avec plusieurs modes d'acquisition et dans des cas normaux et pathologiques. Une série d'images de référence représentatives a été extraite de cette base de données. C'est sur cette série que nous avons travaillé. Le tableau C.1.2 résume les caractéristiques de ces images.

Les images *post* et *epil1* sont des images de patients épileptiques du service d'Epileptologie de l'Hopital La Salpêtrière, dirigé par le Pr Baulac, et acquises au service de Neuroradiologie, dirigé par le Professeur Marsault.

Les images *nass* et *soy2* ont été acquises à l'hôpital Raymond Poincaré, dans le service d'imagerie médicale du Professeur Vallée.

Les images *ton2* et *totex2* ont été acquises au CIERM, à l'hôpital du Kremlin-Bicêtre, dans le service du Professeur Bittoun.

Les images *cu.sag*, *la.sag* et *sa.sag* ont été acquises par l'Unité 280 de l'INSERM en collaboration avec l'Hôpital Neurologique de Lyon.

Nom	taille des images	taille des voxels	plan de	acquisition	commentaires
		$(en mm^3)$	coupe		
cu.sag	$256\times 256\times 182$	0.98~ imes~0.98~ imes	sagittal	MPR3D	Images ré-interpolées à
		0.98			partir de coupes de 1.4
					mm d'épaisseur - Lésion
					post-chirurgicale limitée
					au collicullus inférieur
					droit
epil1	$256 \times 256 \times 124$	$0.94 \times 0.94 \times 1.5$	axial	SPGR	épileptique avec traces
				<b>EI</b> 1 0E	d'électrodes sur le scalp
la.sag	$256 \times 256 \times 191$	$1.0 \times 1.0 \times 1.0$	sagittal	Flash 3D	Images ré-interpolées à
					partir de coupes de 1.5
					mm d'epaisseur - Lesion
					temporale diffuse a la
					sulle a un accident vas-
nass	$256 \times 256 \times 120$	$0.04 \times 0.04 \times 1.5$	avial	Echo de gra	culant
nuss		0.94×0.94×1.5	axiai	dient echo-	contraste
				planar IR 3D	contraste
post	$256 \times 256 \times 124$	$0.94 \times 0.94 \times 1.5$	axial	IR 3D / SPGR	épileptique avec traces
P · ···					d'électrodes sur le cortex
sa.sag	$256\times 256\times 168$	$1.0 \times 1.0 \times 1.0$	sagittal	Flash 3D	Patient épileptique post-
					chirurgical : résection du
					pôle antérieur du lobe
					temporal droit (images
					de qualité moyenne)
soy2	$256 \times 256 \times 122$	$0.94 \times 0.94 \times 1.5$	axial	IR 3D	cas sain
ton2	$256 \times 256 \times 124$	$0.94 \times 0.94 \times 1.5$	sagittal	Echo de gra-	cas sain (bon contraste)
				dient conven-	
				tionnel SPGR	
totex2	$256 \times 256 \times 124$	$0.94 \times 0.94 \times 1.0$	axial	Echo de gra-	
				dient SPGR /	
				IR	

Тав. С.1	– Caracté	éristiques	des	images	de	référence.
----------	-----------	------------	-----	--------	----	------------

# C.2 Présentation des résultats

### C.2.1 Résultats de la segmentation du cerveau

La segmentation du cerveau a été appliquée avec succès sur toutes les images de référence. La table C.2 précise les résultats obtenus sur chacune d'elles. Les résultats sont ilustrés sur les figures C.1 à C.9.

Nom	Seuils	Figure	Commentaires sur les résultats
cu.sag	35 - 120	C.1	Bon résultat. Léger débordement dans le haut de la tête (le cerveau
			inclut un peu de moëlle).
epil1	22 - 125	C.2	Bon résultat.
la.sag	28 - 110	C.3	Il manque du cortex autour de la région pathologique, la partie
			saine est bien segmentée.
nass	5 - 70	C.4	Bon résultat, quelques problèmes dans le haut de la tête : des par-
			ties du cortex manquent dans la région postério-supérieure du
			cerveau, et, dans une moindre mesure, dans les régions antéro-
			latérales. Une partie du vermis du cervelet manque dans les coupes
			les plus inférieures.
post	35 - 150	C.5	Le résultat est bon, les électrodes sont correctement laissées à l'ex-
			térieur du cerveau.
sa.sag	30 - 125	C.6	Le résultat est bon.
soy2	5 - 70	C.7	Même acquisition que nass et les mêmes valeurs de seuil fonc-
			tionnent et donnent un bon résultat. Une partie du pont du système
			nerveux central manque.
ton2	25 - 150	C.8	Très bon résultat, qui inclut complètement les méninges.
totex2	3 - 100	C.9	Le correct est correct, mais des petites parties du cortex sont ou-
			bliées dans la région postéro-supérieure du cerveau. La segmenta-
			tion n'a pas déconnecté le cerveau et d'autres éléments de la tête
			(nez, etc.) dans la région inférieure.

TAB. C.2 – Résultats de la segmentation du cerveau



FIG. C.1 – *Résultat de la segmentation morphologique du cerveau sur l'image* cu.sag, *superposée à quelques coupes du volume original.* 



FIG. C.2 – Résultat de la segmentation morphologique du cerveau sur l'image epil1, superposée à quelques coupes du volume original.



FIG. C.3 – Résultat de la segmentation morphologique du cerveau sur l'image la.sag, superposée à quelques coupes du volume original.



FIG. C.4 – Résultat de la segmentation morphologique du cerveau sur l'image nass, superposée à quelques coupes du volume original.



FIG. C.5 – Résultat de la segmentation morphologique du cerveau sur l'image post, superposée à quelques coupes du volume original.



FIG. C.6 – *Résultat de la segmentation morphologique du cerveau sur l'image* sa.sag, *superposée à quelques coupes du volume original.* 



FIG. C.7 – Résultat de la segmentation morphologique du cerveau sur l'image soy2, superposée à quelques coupes du volume original.



FIG. C.8 – *Résultat de la segmentation morphologique du cerveau sur l'image* ton2, *superposée à quelques coupes du volume original.*


FIG. C.9 – *Résultat de la segmentation morphologique du cerveau sur l'image* totex2, *superposée à quelques coupes du volume original.* 

### C.2.2 Exemples de résultat d'estimation

La figure C.10 présente quelques résultats d'estimation à partir des histogrammes des cerveaux segmentés. L'estimation est entièrement automatique, et simultanée pour toutes les classes recherchées. Les images *cu.sag*, *la.sag* et *sa.sag* n'ont pas été traitées à partir d'ici, car nous ne disposons que d'images requantifiées su 8 bits pour lesquelles l'histogramme est en dents de scie.

Les seuils utilisés dans toute la suite ont été appris en calculant la moyenne et l'écart-type de chaque classe dans chaque image à partir de cet apprentissage. Les statistiques obtenues sur les quatre images montrées en exemple sont regroupées dans le tableau C.3. Le fait de prendre en compte dans le calcul tous les points (pondérés par leur degré d'appartenance) ou seulement ceux dont l'appartenance à la classe considérée est supérieure à 0,5 modifie essentiellement les variances des classes et les moyennes du liquide céphalo-rachidien, et très peu les moyennes des substances grise et blanche. Ces constations correspondent bien au fait que c'est essentiellement au niveau du liquide céphalo-rachidien des sillons que s'observe le plus fort effet de volume partiel.

Nom	$\mu_{LCR}$	$\sigma_{LCR}$	$\mu_{SGR}$	$\sigma_{SGR}$	$\mu_{SBL}$	$\sigma_{SBL}$
nass	15,61 - 12,22	7,02 - 5,38	32,91 - 32, 91	6,20 - 5,23	53,75 - 54.28	6,68 - 6,41
soy2	14,45 - 12,49	5,74 - 4,90	31,81 - 31,53	6,11 - 5,07	52,81 - 53,71	6,93 - 6,40
ton2	58,69 - 53,75	18,19 - 14,92	100,68 - 100,65	11,34 - 8,66	131,64 - 133,26	8,50 - 7,13
totex2	12,00 - 9,10	6,23 - 4,39	28,14 - 28,14	6,86 - 4,98	48,52 - 50,19	7,47 - 6,32

TAB. C.3 – Moyenne et écart-type de chaque classe obtenus par apprentissage automatique. Deux valeurs sont données pour chaque paramètre, correspondant aux valeurs obtenues en considérant tous les points pour le calcul ou seulement ceux d'appartenance supérieure à 0,5 respectivement.



FIG. C.10 – *Estimation des fonctions d'appartenance au liquide céphalo-rachidien, substance grise et substance blanche sur* nass, soy2, ton2 *et* totex2.

## C.2.3 Résultats de la segmentation du liquide céphalo-rachidien des sillons et des ventricules

Les résultats de la segmentation du liquide céphalo-rachidien des sillons et des ventricules sont présentés dans les figures C.11 à C.16. La table C.4 regroupe les paramètres utilisés et commente les résultats.

Nom	Seuils et $\mu_{LCR}$	Figure	Commentaires sur les résultats	
epil1	33 - 60 - 23	C.11	Les résultats sont corrects pour les sillons et les ventricules. La	
			segmentation a même pu distinguer le 4ème ventricule. En re-	
			vanche, les citernes (supérieures au cervelet) sont segmentées à	
			tort comme partie des ventricules.	
nass	18 - 30 - 12	C.12	La qualité du résultat est similaire à celle obtenue pour epil1.	
post	50 - 80 - 30	C.13	Les sillons sont très bien localisés. Les ventricules ne sont que	
			partiellement obtenus.	
soy2	20 - 28 - 12	C.14	Bon résultat. Même problème avec les citernes que pour epill. Des	
			petites parties des sillons dans la partie postérieure sont étiquetés	
			ventricules.	
ton2	62 - 95 - 53	C.15	Très bonne localisation des sillons. Bonne segmentation des ven-	
			tricules, y compris les ventricules 3 et 4.	
totex2	23 - 25 - 12	C.16	Une partie importante des sillons du cervelet et de la scissure inter-	
			hémisphérique est segmentée comme système ventriculaire. De	
			trop grande largeur, elle n'a pas été déconnectée des ventricules.	

TAB. C.4 – Résultats de la segmentation du liquide céphalo-rachidien des sillons et des ventricules



FIG. C.11 – Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons et des ventricules sur l'image epil1, superposée à quelques coupes du volume original.



FIG. C.12 – Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons et des ventricules sur l'image nass, superposée à quelques coupes du volume original.



FIG. C.13 – Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons et des ventricules sur l'image post, superposée à quelques coupes du volume original.



FIG. C.14 – Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons et des ventricules sur l'image soy2, superposée à quelques coupes du volume original.



FIG. C.15 – Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons et des ventricules sur l'image ton2, superposée à quelques coupes du volume original.



FIG. C.16 – Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons et des ventricules sur l'image totex2, superposée à quelques coupes du volume original.

### C.2.4 Résultats de la segmentation du cortex et des noyaux centraux

Nous illustrons ici les résultats obtenus pour les noyaux centraux lors de la segmentation de la substance grise (figures C.17 à C.22). Les résultats pour le cortex seront illustrés d'une part par l'interface gris/blanc et d'autre part par les résultats de la segmentation globale. Le tableau C.5 commente ces résultats. De manière générale, les informations obtenues sur les noyaux doivent être considérées plus comme des marqueurs que comme une segmentation précise. Cela est dû en grande partie au problème de volume partiel à la périphérie des noyaux. Nous avons pris un deuxième seuil légèrement supérieur à  $\mu_{SBL} \Leftrightarrow 2\sigma_{SBL}$ . Cela permet d'avoir des noyaux beaucoup plus complets qu'en prenant exactement  $\mu_{SBL} \Leftrightarrow 2\sigma_{SBL}$ , mais en revanche, cela induit des fausses détections dans le bas du cerveau. Ces fausses détections sont partiellement éliminées par la dernière étape globale de regroupement des segmentations.

Nom	Seuils	Figure	Commentaires sur les résultats	
epil1	40 - 76	C.17	Bons marqueurs pour les thalami, noyaux caudés et putamen. De	
			petites fausses détections apparaissent sur les coupes inférieures.	
nass	18 - 45	C.18	Résultats similaires à ceux obtenus sur epil1. De fausses détections	
			apparaissent dans les régions postérieures du 3ème ventricule.	
post	50 - 100	C.19	De bons marqueurs sont obtenus.	
soy2	20 - 43	C.20	Bons marqueurs mais beaucoup d'erreurs dans les sillons de la	
			région supérieure au cervelet et postérieure au 3ème ventricule.	
ton2	62 - 125	C.21	Bons marqueurs mais quelques erreurs dans la partie postérieure	
			du tronc cérébral et dans la partie supérieure du cervelet.	
totex2	23 - 45	C.22	Très bons marqueurs, proches de la segmentation idéale, mais	
			beaucoup de fausses détections au niveau de la scissure inter-	
			hémisphérique et à proximité du cervelet (provenant en grande par-	
			tie des erreurs dans la distinction entre le liquide céphalo-rachidien	
			des sillons et celui des ventricules dans ces régions).	

TAB. C.5 – Résultats de la segmentation des noyaux centraux



FIG. C.17 – Résultat de la segmentation morphologique des noyaux centraux sur l'image epil1, superposée à quelques coupes du volume original.



FIG. C.18 – Résultat de la segmentation morphologique des noyaux centraux sur l'image nass, superposée à quelques coupes du volume original.



FIG. C.19 – Résultat de la segmentation morphologique des noyaux centraux sur l'image post, superposée à quelques coupes du volume original.



FIG. C.20 – Résultat de la segmentation morphologique des noyaux centraux sur l'image soy2, superposée à quelques coupes du volume original.



FIG. C.21 – Résultat de la segmentation morphologique des noyaux centraux sur l'image ton2, superposée à quelques coupes du volume original.



FIG. C.22 – *Résultat de la segmentation morphologique des noyaux centraux sur l'image* totex2, *superposée à quelques coupes du volume original.* 

### C.2.5 Interface gris/blanc

Nous présentons ici les résultats obtenus pour l'interface entre substance grise et substance blanche, déduite des segmentations précédentes (figures C.23 à C.28). Les contours présentés comprennent à la fois le bord interne du ruban cortical et les limites avec les noyaux centraux.

De manière générale, les résultats se caractérisent par les deux points suivants :

- le tronc cérébral est souvent segmenté comme substance blanche;
- la détection est correcte à la fois dans l'encéphale et dans le cervelet.

Remarquons également les bons résultats obtenus au niveau du corps calleux (voir en particulier la figure C.27).



FIG. C.23 – *Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image* epil1, *superposée à quelques coupes du volume original.* 



FIG. C.24 – *Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image* nass, *superposée à quelques coupes du volume original.* 



FIG. C.25 – *Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image* post, *superposée à quelques coupes du volume original.* 



FIG. C.26 – *Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image* soy2, *superposée à quelques coupes du volume original.* 

Annexe C. Résultats de segmentation morphologique

373



FIG. C.27 – *Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image* ton2, *superposée à quelques coupes du volume original.* 



FIG. C.28 – *Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image* totex2, *superposée à quelques coupes du volume original.* 

### C.2.6 Résultats globaux

Finalement, nous illustrons les résultats de la segmentation globale, obtenus en imposant des priorités entre les segmentations des structures obtenues séparément.

La figure C.29 montre une vue en perspective construite à partir des résultats obtenus sur *epil1*. Les figures C.30 à C.35 montrent les résultas obtenus sur les images de référence.



FIG. C.29 – Une vue en perspective de la segmentation obtenue sur epil1.



FIG. C.30 – *Résultat de la segmentation globale sur l'image* epil1, *superposée à quelques coupes du volume original.* 



FIG. C.31 – *Résultat de la segmentation globale sur l'image* nass, *superposée à quelques coupes du volume original.* 



FIG. C.32 – *Résultat de la segmentation globale sur l'image* post, *superposée à quelques coupes du volume original.* 



FIG. C.33 – Résultat de la segmentation globale sur l'image soy2, superposée à quelques coupes du volume original.



FIG. C.34 – *Résultat de la segmentation globale sur l'image* ton2, *superposée à quelques coupes du volume original.* 



FIG. C.35 – *Résultat de la segmentation globale sur l'image* totex2, *superposée à quelques coupes du volume original.* 

### Annexe D

# La bibliothèque TIVOLI de traitements d'images

Lorsque nous avons entamé cette thèse, le département Images de l'E.N.S.T. ne possédait pas de bibliothèque de traitements d'images tridimensionnelles. Une part importante de notre travail a consisté en l'élaboration d'une telle bibliothèque, que nous avons baptisée *TIVOLI*.

### **D.1** Cahier des charges

Les contraintes que devait respecter cette bibliothèque étaient les suivantes :

- contenir des traitements classiques destinés à des images numériques tridimensionnelles comme bidimensionnelles,
- gérer l'anisotropie éventuelle des images,
- accepter le format d'images du laboratoire,
- fonctionner sous Unix,
- proposer aussi bien des commandes en ligne que des fonctions qui puissent être appelées à partir d'un programme écrit en C,
- fournir une aide aux utilisateurs,
- être facilement manipulable et augmentable.

### **D.2** Point de vue critique

Les avantages principaux TIVOLI sont :

- sa portabilité due au C ANSI,
- sa rapidité d'exécution,
- sa fiabilité,
- la multitude de traitements proposés,

- l'existence d'un mode traceur (permettant de suivre l'exécution d'une chaîne de traitements),
- l'existence d'un mode de test (permettant de lancer l'exécution d'une chaîne de traitements sans que ceux-là ne soient réellement réalisés, donc de tester la cohérence de l'enchaînement des entrées-sorties des traitements).

Ses principaux inconvénients sont:

- l'absence d'un environnement de programmation graphique,
- un manque de généricité.

Ce dernier point mérite d'être détaillé. La plupart des traitements ont été écrits pour des images dont les valeurs de point sont codées sur 8 bits non signés (0..255); aussi, pour réaliser un tel traitement avec un autre type de données, il faut copier-coller son code puis l'adapter au nouveau type...

### **D.3** Contributions

Ses principaux contributeurs sont les suivants:

Thierry Géraud	conception, entrées-sorties, visualisation,
	traitements élémentaires sur les niveaux, morphologie
	mathématique, champs de Markov, recalage, classification,
	opérateurs directionnels binaire⇔flou, maintenance
Isabelle Bloch	opérateurs de fusion floue, morphologie floue,
	opérateurs directionnels flou⇔ flou, distances floues
Bert Verdonck	conversions de formats, projection par maximum d'intensité,
	génération de bruit, de volumes synthétiques, maintenance
Dimitri Papadopoulos-Orfanos	conception, ajout du memory mapping, maintenance

sans oublier Anne Robert et Lars Aurdal.

Depuis, de nouveaux thésards ont repris le flambeau; citons en particulier Yann Cointepas et Aymeric Perchant.

Actuellement TIVOLI comporte plus de 50 000 lignes de C et propose plus de 45 commandes en ligne paramétrables à l'aide d'options.

### **D.4** Exemple

La commande en ligne suivante :

t\_icm -i lena2 -g gauss3.txt -p potts3.txt -s

donne le résultat montré en figure D.1; son secret de fabrication réside dans les deux fichiers de paramètres...




## Bibliographie

- [ACKE-91] M. ACKERMAN, *The visible human project*, Journal of Biocommunications, Vol. 2, No. 18, 1991, p. 14.
- [ADAM-91] C. ADAMSBAUM, Imagerie quantitative des lésions nerveuses de l'adrénoleukodystrophie par résonance magnétique nucléaire, rapp. tech., Hôpital St. Vincent de Paul, 1991.
- [AGAR-92] I. AGARTZ, J. SÄÄF, L. WALHLUND, ET L. WETTERBERG, Quantitative estimations of cerebrospinal fluid spaces and brain regions in healthy controls using computer-assisted tissue classification of magnetic resonance images: relation to age and sex, Journal of Magnetic Resonance Imaging, Vol. 10, 1992, pp. 217–226.
- [ALLA-92] P. ALLAIN, J. TRAVÈRE, ET J. BARON, Multimodality: 3D MRI analysis as a primary tool for PET acquisition referenced to an anatomical database, in IEEE 3D Advanced Image Processing in Medicine, Rennes, France, 1992, pp. 201–203.
- [ALLA-93] P. ALLAIN, Imagerie par résonnance magnétique du cerveau : analyse tridimensionnelle et segmentation, Thèse de doctorat, Université de Caen, France, 1993.
- [AMAR-92] S. AMARTUR, D. PIRAINO, ET Y. TAKEFUJI, Optimization neural networks for the segmentation of magnetic resonance images, IEEE Transactions on Medical Imaging, Vol. 11, 1992, pp. 215–220.
- [ANDE-73] M. ANDERBERG, *Cluster analysis for application*, Academic Press, New York, 1973.
- [ANDR-94a] N. ANDREASEN, S. ARNDT, V. SWAYZE, T. CIZADLO, M. FLAUM, J. EHRHARDT, ET W. YUH, *Thalamic abnormalities in schizophrenia visualized through magnetic resonancce imag averaging*, Science, Vol. 266, 1994, pp. 294–298.
- [ASHT-90] M. ASHTARI, J. ZITO, B. GOLD, J. LIEBERMAN, M. BORENSTEIN, ET P. HER-MAN, Computerized volume measurement of brain structure, Investigative Radiology, Vol. 25, 1990, pp. 798–805.
- [ASHT-95] E. ASHTON, M. BERG, K. PARKER, J. WEISBERG, C. CHEN, ET L. KETONEN, Segmentation and feature extraction techniques, with applications to MRI head studies, Magn. Reson. Med., Vol. 33, 1995, pp. 670–677.
- [ATKI-97] D. ATKINSON, D. HILL, P. STOYLE, P. SUMMERS, ET S. KEEVIL, Automatic correction of motion artifacts in magnetic resonance images using an entropy focus criterion, IEEE Transactions on Medical Imaging, Vol. 16, No. 6, 1997, pp. 903–910.

- [AURD-97] L. AURDAL, Analysis of multi-image magnetic resonance acquisitions for segmentation and quantification of cerebral pathologies, Thèse de doctorat, École Nationale Supérieure des Télécommunications, Paris, France, 1997.
- [AZEN-92] R. AZENCOTT ET C. GRAFFIGNE, Non supervised segmentation using multilevel Markov random fields, in International Conference on Pattern Recognition, vol. 3, The Hague, The Nederlands, 1992, pp. 201–204.
- [BAIL-97] R. BAJCSY, R. LIEBERSON, ET M. REIVICH, A Bayesian approach to introducing anatomo-functional priors in the EEG/MEG inverse problem, IEEE Transactions on Biomedical Engineering, Vol. 44, No. 5, 1997, pp. 374–385.
- [BAJC-83] —, A computerized system for the elastic matching of deformed radiographic images to idealized atlas images, Journal of Computer Assisted Tomography, Vol. 7, No. 4, 1983, pp. 618–625.
- [BAJC-89] R. BAJCSY ET S. KOVACIC, *Multiresolution elastic matching*, Computer Vision, Graphics, and Image Processing, Vol. 46, 1989, pp. 1–21.
- [BALL-65] G. BALL ET D. HALL, *ISODATA*, a novel method of data analysis and pattern classification, rapp. tech., Stanford Research Institute, 1965.
- [BALL-67] G. BALL ET D. HALL, A clustering technique for summarizing multivariate data, Behav. Sci., Vol. 12, 1967, pp. 153–155.
- [BARR-79] M. BARR, *The human nervous system an anatomic viewpoint*, Harper & Row, Hagerstown, 1979.
- [BENS-94b] A. BENSAID, Improved fuzzy clustering for pattern recognition with applications to image segmentation, Thèse de doctorat, Tampa, University of South Florida, U.S.A., 1994.
- [BERT-94b] G. BERTRAND, Simple points, topological numbers and geodesic neighborhoods in cubic grids, Pattern Recognition Letters, Vol. 15, 1994, pp. 1003–1010.
- [BESA-74] J. BESAG, *Spatial interaction and the statistical analysis of lattice systems*, Journal of the Royal Statistical Society, Vol. 36, 1974, pp. 192–236.
- [BESA-86] —, On the statistical analysis of dirty pictures, Journal of the Royal Statistical Society, Vol. 48, No. 3, 1986, pp. 259–302.
- [BESL-92] P. BESL ET N. MCKAY, *A method for registration of 3D shapes*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 14, No. 2, 1992, pp. 239–256.
- [BEZD-73] J. BEZDEK, *Fuzzy mathematics in pattern classification*, Thèse de doctorat, Cornell University, Ithaca, 1973.
- [BEZD-93] J. BEZDEK, L. HALL, ET L. CLARKE, *Review of MR image segmentation techniques using pattern recognition*, Medical Physics, Vol. 20, No. 4, 1993, pp. 1033–1048.
- [BHAR-85] B. DEVI ET V. SARMA, Estimation of fuzzy memberships from histograms, Information Sciences, Vol. 35, 1985, pp. 43–59.

- [BIND-86] K. BINDER ET A. YOUNG, Spin glasses: experimental facts, theorical concepts, and open questions, Reviews of Modern Physics, Vol. 58, No. 4, 1986, pp. 43–59.
- [BLAK-87] A. BLAKE ET A. ZISSERMAN, Visual reconstruction, MIT Press, Cambridge, 1987.
- [BLAT-95] D. BLATTER, E. BIGLER, S. GALE, S. JOHNSON, C. ANDERSON, B. BURNETT, N. PARKER, S. KURTH, ET S. HORN, *Quantitative volumetric analysis of brain MR: normative database spanning five decades of life*, American Journal of Neuroradiology, Vol. 16, No. 2, 1995, pp. 241–251.
- [BLOC-93] I. BLOCH ET H. MAÎTRE, *Constructing a fuzzy mathematical morphology: alternative ways, in* IEEE International Conference on Fuzzy Systems, 1993, pp. 1303–1308.
- [BLOC-94b] I. BLOCH, *Fuzzy sets in image processing, in* ACM Symposium on Applied Computing, Phoenix, Arizona, U.S.A., 1994, pp. 175–179.
- [BLOC-95a] I. BLOCH ET H. MAÎTRE, *Fuzzy mathematical morphologies: a comparative study*, Pattern Recognition, Vol. 28, No. 9, 1995, pp. 1341–1387.
- [BLOC-95b] I. BLOCH, *Fuzzy distances and image processing, in* ACM Symposium on Applied Computing, Nashville, U.S.A., 1995, pp. 570–574.
- [BLOC-96a] —, Distances in fuzzy sets for image processing derived from fuzzy mathematical morphology, in Information Processing and Management of Uncertainty in Knowledge-Based Systems, vol. 3, Granada, Spain, 1996, pp. 1307–1312.
- [BLOC-96b] —, Fuzzy spatial relationships: a few tools for model-based pattern recognition in aerial images, in SPIE EUROPTO Conference on Image and Signal Processing for Remote Sensing, vol. 2955, Taormina, Italy, 1996, pp. 141–152.
- [BLOC-96c] —, Information combination operators for data fusion: a comparative review with classification, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 26, No. 1, 1996, pp. 52–67.
- [BLOC-96e] —, Fuzzy relative position between objects in images: a morphological approach, in IEEE International Conference on Image Processing, vol. 2, Lausanne, Switzerland, 1996, pp. 987–990.
- [BLOC-97a] I. BLOCH, L. AURDAL, D. BIJNO, ET J. MÜLLER, Estimation of class membership functions for grey-level based image fusion, in IEEE International Conference on Image Processing, vol. 3, Santa Barbara, California, U.S.A., 1997, pp. 268–271.
- [BLOC-97c] I. BLOCH, Fuzzy relative position between objects in image processing: a morphological approach, rapp. tech., École Nationale Supérieure des Télécommunications, Paris, France, 1997.
- [BOMA-90] M. BOMANS, K. HÖHNE, U. TIEDE, ET M. RIEMER, 3D segmentation of MR images of the head for 3D display, IEEE Transactions on Medical Imaging, Vol. 9, No. 2, 1990, pp. 177–183.
- [BOOK-89] F. BOOKSTEIN, Principal warps: thin-plate splines and the decomposition of deformations, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 11, No. 6, 1989, pp. 567–585.

## 390 Bibliographie

- [BOOK-91] \_\_\_\_\_, *Thin plate splines and the atlas problem for biomedical images, in* International Conference on Information Processing in Medical Imaging, 1991, pp. 326–342.
- [BOOK-96] —, Shape and the information in medical images: a decade of the morphometric synthesis, in Mathematical Methods in Biomedical Image Analysis, San Francisco, California, U.S.A., 1996, pp. 2–12.
- [BORG-86] G. BORGEFORS, *Distance transformations in digital images*, Computer Vision, Graphics, and Image Processing, Vol. 34, 1986, pp. 344–371.
- [BOUM-91] C. BOUMAN ET B. LIU, Multiple resolution segmentation of textured images, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 13, No. 2, 1991, pp. 99–113.
- [BOUM-92] C. BOUMAN ET M. SHAPIRO, *Multispectral image segmentation using a multiscale model*, *in* IEEE International Conference on Acoustics, Speech, and Signal Processing, vol. 3, San Francisco, California, U.S.A., 1992, pp. 565–568.
- [BOUT-90] P. BOUTHEMY, F. HEITZ, P. LALANDE, ET E. FRANÇOIS, Analyse du mouvement et modélisation par champs markoviens, in XXIIe Journées de Statistiques, Tours, France, 1990.
- [BRAD-95] S. BRADLEY, C. ROSSE, ET J. BRINKLEY, Web-based access to an online atlas of anatomy: the digital anatomist common gateway interface, in Symposium on Computer Applications in Medical Care, New Orleans, U.S.A., 1995, pp. 512–516.
- [BRAN-94] M. BRANDT, T. BOHAN, L. KRAMER, ET J. FLETCHER, Estimation of CSF, white and gray matter volumes in hydrocephalic children using fuzzy clustering of MR images, Computerized Medical Imaging and Graphics, Vol. 18, No. 1, 1994, pp. 25– 34.
- [BRIN-93] J. BRINKLEY, K. ENO, ET J. SUNDSTEN, Knowledge-based client-server approach to structural information retrieval: the digital anatomist browser, Computer Methods and Programs in Biomedicine, Vol. 40, 1993, pp. 131–145.
- [BROI-81] C. BROIT, *Optimal registration of deformed images*, Thèse de doctorat, University of Pennsylvania, Philadelphia, 1981.
- [BRUM-92] M. BRUMMER, Optimzed intensity thresholds for volumetric analysis of magnetic resonance imaging data, in SPIE Visualization in Biomedical Computing, R. Robb, ed., vol. 1808, Chapel Hill, North Carolina, U.S.A., 1992, pp. 299–310.
- [CANN-86a] J. CANNY, A computational approach to edge detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 8, No. 6, 1986, pp. 679–698.
- [CARL-95] I. CARLBOM, G. KLINKER, D. TERZOPOULOS, ET L. THURFJELL, Generalpurpose soft tissue segmentation from medical images, in Scandinavian Conference on Image Analysis, Uppsala, Sweden, 1995, pp. 905–912.
- [CARP-91] M. CARPENTER, Core text of neuroanatomy, Williams & Wilkins, Baltimore, 1991.

- [CELE-89] G. CELEUX, E. DIDAY, G. GOVAERT, Y. LECHEVALLIER, ET H. RALAMBON-DRAINY, Classification automatique des données – environnement statitique et informatique, Dunod Informatique, Paris, 1989.
- [CHAU-95] S. CHAUVIN, Evaluation des théories de la décision appliquées à la fusion de capteurs en imagerie satellitaire, Thèse de doctorat, Université de Nantes, France, 1995.
- [CHEN-94b] C. CHEN, T. HUANG, ET M. ARROTT, Modeling, analysing and visualization of left-ventricle shape and motion by hierarchical decomposition, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 16, No. 4, 1994, pp. 342–356.
- [CHEN-95] S. CHEN, M. YEH, ET P. HSIO, *A comparison of similarity measures of fuzzy values*, Fuzzy Sets and Systems, Vol. 72, 1995, pp. 79–89.
- [CHEN-96] K. CHENG, J. LIN, ET C. MAO, The application of competitive hopfield neural network to medical image segmentation, IEEE Transactions on Medical Imaging, Vol. 15, 1996, pp. 560–567.
- [CHO-88] Z. CHO, D. KIM, ET Y. KIM, Total inhomogeneity correction including chemical shifts and susceptibility by view angle, Medical Physics, Vol. 15, No. 1, 1988, pp. 7– 11.
- [CHOI-91] H. CHOI, D. HAYNOR, ET Y. KIM, Partial volume tissue classification of multichannel magnetic resonance images – a mixel model, IEEE Transactions on Medical Imaging, Vol. 10, No. 3, 1991, pp. 395–407.
- [CHOI-97] S. CHOI, J. LEE, J. KIM, ET M. KIM, Volumetric object reconstruction using the 3D-MRF model-based segmentation, IEEE Transactions on Medical Imaging, Vol. 16, No. 6, 1987, pp. 887–892.
- [CHOW-65] C. CHOW, *Statistical independence and threshold functions*, IEEE Transactions on Electronic Computers, Vol. 16, 1965, pp. 66–68.
- [CHRI-93] G. CHRISTENSEN, R. RABBITT, ET M. MILLER, A deformable neuroanatomy textbook based on viscous fluid mechanics, in Conference on Information Sciences and Systems, 1993, pp. 211–216.
- [CHRI-94] —, *3D brain mapping using a deformable neuroanatomy*, Phys. Med. Biol., Vol. 39, 1994, pp. 609–618.
- [CIVA-86] M. CIVANLAR ET H. TRUSSEL, *Constructing membership functions using statistical data*, Fuzzy Sets and Systems, Vol. 18, 1986, pp. 1–13.
- [CLAR-93] L. CLARKE, R. VELTHUIZEN, S. PHUPHANICH, J. SCHELLENBERG, J. ARRING-TON, ET M. SILBIGER, *MRI: stability of three supervised segmentation techniques*, Journal of Magnetic Resonance Imaging, Vol. 11, 1993, pp. 95–106.
- [CLAR-94] M. CLARK, L. HALL, D. GOLDGOF, L. CLARKE, R. VELTHUIZEN, ET M. SIL-BIGER, MRI segmentation using fuzzy clustering techniques, IEEE Engineering in Medicine and Biology, Vol. 13, No. 5, 1994, pp. 730–742.

- [CLAR-95] L. CLARKE, R. VELTHUIZEN, M. CAMACHO, J. HEINE, M. VAIDYANATHAN, L. HALL, R. THATCHER, ET M. SILBIGER, *MRI segmentation: methods and applications*, Journal of Magnetic Resonance Imaging, Vol. 13, No. 3, 1995, pp. 343–368.
- [CLEM-85] C. CLEMENTE, Gray's anatomy, Lea & Febiger, Philadelphia, 1985.
- [CLIN-87] H. CLINE, C. DUMOULIN, H. HART, W. LORENSEN, ET S. LUDKE, 3D reconstruction of the brain from magnetic resonance images using a connectivity algorithm, Journal of Magnetic Resonance Imaging, Vol. 5, 1987, pp. 345–352.
- [CLIN-91] H. CLINE, W. LORENSEN, S. SOUZA, F. JOLESZ, R. KIKINIS, G. GERIG, ET T. KENNEDY, 3D surface rendered MR images of the brain and its vasculature, Journal of Computer Assisted Tomography, Vol. 15, No. 2, 1991, pp. 344–351.
- [COCO-97] C. COCOSCO, V. KOLLOKIAN, R. KWAN, ET A. EVANS, BrainWeb: online interface to a 3D MRI simulated brain database, in International Conference on Functional Mapping of the Human Brain, Copenhagen, Danemark, 1997.
- [COHE-91] L. COHEN, *On active contour models and balloons*, CVGIP: Image Understanding, Vol. 53, No. 2, 1991, pp. 211–218.
- [COHE-92a] I. COHEN, L. COHEN, ET N. AYACHE, Using deformable surfaces to segment 3D images and infer differential structures, CVGIP: Image Understanding, Vol. 56, No. 2, 1992, pp. 242–263.
- [COHE-92b] G. COHEN, N. ANDREASEN, R. ALLIGER, S. ARNDT, J. KUAN, W. YUH, ET J. EHRHARDT, Segmentation techniques for the classification of brain tissue using magnetic resonance imaging, Psychiatry Research: Neuroimaging, Vol. 45, 1992, pp. 33-51.
- [COHE-92c] L. COHEN ET I. COHEN, Deformable models for 3D medical images using finite elements and baloons, in IEEE International Conference on Computer Vision and Pattern Recognition, 1992, pp. 592–598.
- [COHE-93] L. COHEN ET I. COHEN, Finite element methods for active contour models and balloons in 2D and 3D images, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 15, No. 11, 1993, pp. 1131–1147.
- [COLL-87] COLL., *The Oxford companion to the mind*, Oxford University Press, New York Oxford, 1987.
- [COLL-93] \_\_\_\_, Le cerveau : un inconnu, Robert Laffont Ed., Paris, 1993.
- [COLL-94] D. COLLINS, P. NEELIN, T. PETERS, ET A. EVANS, *Automatic 3D intersubject registration of MR volumetric data in standardized Talairach space*, Journal of Computer Assisted Tomography, Vol. 18, No. 2, 1994, pp. 192–205.
- [CONN-91] W. CONNOR ET P. DIAZ, Morphological segmentation and 3D rendering of the brain in magnetic resonance imaging, in SPIE Image Algebra and Morphological Image Processing, vol. 1568, 1991, pp. 327–334.

- [CUTT-93] C. CUTTING, F. BOOKSTEIN, B. HADDAD, D. DEAN, ET D. KIM, *A spline-based* approach for averaging three-dimensional curves and surfaces, in SPIE Mathematical Methods in Medical Imaging II, San Diego, California, U.S.A., 1993, pp. 29–44.
- [DAIL-96] D. DAILEY ET J. BRINKLEY, A metric for quantifying response time in a browser application, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 26, No. 2, 1996, pp. 271–275.
- [DAWA-91] B. DAWANT, M. ÖZKAN, A. ZIJDENBOS, ET R. MARGOLIN, A computer environment for 2D and 3D quantitation of MR images using neural networks, in IEEE International Conference on Engineering in Medicine and Biology Society, 1991, pp. 64– 65.
- [DEAR-76] S. DEARMOND, M. FUSCO, ET M. DEWEY, *Structure of the human brain a photographic atlas*, Oxford University Press, New York, 1976.
- [DELG-87] M. DELGADO ET S. MORAL, *On the concept of possibility-probability consistency*, Fuzzy Sets and Systems, Vol. 21, No. 3, 1987, pp. 311–318.
- [DELL-92] S. DELLEPIANE, G. VENTURI, ET G. VERNAZZA, Model generation and model matching of real images by a fuzzy approach, Pattern Recognition, Vol. 25, No. 2, 1992, pp. 115–137.
- [DERI-87] H. DERIN ET H. ELLIOTT, Modeling and segmentation of noisy and textured images using Gibbs random fields, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 9, No. 1, 1987, pp. 39–55.
- [DERO-95] D. DEROU, *Optimisation neuronale et régularisation multiéchelle auto-organisée pour la trajectograaphie de particules*, Thèse de doctorat, Institut National Polytechnique de Grenoble, France, 1995.
- [DESC-93] X. DESCOMBES, *Champs markoviens en analyse d'images*, Thèse de doctorat, École Nationale Supérieure des Télécommunications, Paris, France, 1993.
- [DESM-97] J. DESMOND ET K. LIM, On- and offline talairach registration for structural and functional mri studies, Human Brain Mapping, Vol. 5, No. 1, 1997, pp. 58–73.
- [DIDA-70] E. DIDAY, Une nouvelle méthode de classification automatique et de reconnaissance des formes : la méthode des nuées dynamiques, Revue de Statistique Appliquée, Vol. 19, No. 2, 1970.
- [DIGE-94] V. D. GESÙ ET L. ROMEO, An application of integrated clustering to MRI segmentation, Pattern Recognition Letters, Vol. 15, 1994, pp. 731–738.
- [DINT-90] J. DINTEN, Tomography reconstruction of axially symmetric objects: regularization by a Markovian modelization, in International Conference on Pattern Recognition, Atlantic City, U.S.A., 1990, pp. 153–158.
- [DUBO-83] D. DUBOIS ET H. PRADE, On distance between fuzzy points and their use for plausible reasoning, in International Conference on Systems, Man, and Cybernetics, 1983, pp. 300–303.

- [DUBO-85] —, A review of fuzzy set aggregation connectives, Information Sciences, Vol. 36, 1985, pp. 85–121.
- [DUBO-88] —, Weighted fuzzy pattern matching, Fuzzy Sets and Systems, Vol. 28, 1988, pp. 313–331.
- [DUBU-90] B. DUBUISSON, Diagnostic et reconnaissance des formes, Hermès, Paris, 1990.
- [DUDA-73] R. DUDA ET P. HART, *Pattern classification and scene analysis*, Wiley-Interscience, 1973.
- [DUNK-75] G. DUNKERLEY, A basic atlas of the human nervous system, F.A. Davis, Philadelphia, 1975.
- [DUNN-74] J. DUNN, A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters, Journal of Cybernetics, Vol. 3, 1974, pp. 32–57.
- [DUVE-92] H. DUVERNOY, E. CABANIS, M. IBA-ZIZEN, J. TAMRAZ, ET J. GUYOT, Le cerveau humain: surface, coupes sériées tridimensionnelles et IRM, Springer-Verlag, Paris, 1992.
- [EHRI-90] H. EHRICKE, Problems and approaches for tissue segmentation in 3D-MR imaging, in SPIE Medical Imaging IV: Image Processing, vol. 1233, 1990, pp. 128–137.
- [EVAN-88] A. EVANS, C. BEIL, S. MARRETT, C. THOMPSON, ET A. HAKIM, Anatomicalfunctional correlation using and adjustable MRI-based region of interest atlas with Positron Emission Tomography, Journal of Cerebral Blood Flow and Metabolism, Vol. 8, 1988, pp. 513–530.
- [EVAN-96] A. EVANS, D. COLLINS, ET C. HOLMES, Computational approaches to quantifying human neuroanatomical variability, A.W. Toga and J.C. Mazziotta, Academic Press, 1996, pp. 343–361.
- [EVER-71] N. EVERETT, Functional neuroanatomy, Lea & Febiger, Philadelphia, 1971.
- [EVIA-96] H. EVIATAR ET R. SOMORJAI, A fast simple active contour algorithm for biomedical *images*, Pattern Recognition Letters, Vol. 17, No. 9, 1996, pp. 969–974.
- [FABE-88] T. FABER ET E. STOKELY, Orientation of 3D structures in medical images, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 10, No. 5, 1988, pp. 626–633.
- [FADI-97] J. FADILLI, S. RUAN, L.VERARD, C. JAGGI, ET D. BLOYET, Extraction et partitionnement de l'encéphale par un modèle de contours actifs, in Colloque sur le Traitement du Signal et des Images (GRETSI), Grenoble, France, 1997, pp. 439–442.
- [FELD-96] J. FELDMAR, G. MALANDAIN, J. DECLERCK, ET N. AYACHE, Extension of the ICP algorithm to non-rigid intensity-based registration of 3D volumes, in Mathematical Methods in Biomedical Image Analysis, San Francisco, California, U.S.A., 1996, pp. 84–93.
- [FENE-67] H. FENEIS, Anatomische Bildnomenklatur, Georg Thieme Verlag, Stuttgart, 1967.

- [FESS-94] J. FESSLER, A mixture-site model for edge-preserving image restoration, in IEEE International Conference on Image Processing, vol. 3, Austin, Texas, U.S.A., 1994, pp. 162–166.
- [FLAS-97] N. FLASQUE, M. DESVIGNES, ET M. REVENU, Coopération de modèles déformables pour l'imagerie cérébrale en 3 dimensions, in Colloque sur le Traitement du Signal et des Images (GRETSI), Grenoble, France, 1997, pp. 733–736.
- [FLET-93] L. FLETCHER, J. BARSOTTI, ET J. HORNAK, A multispectral analysis of brain tissues, Magn. Reson. Med., Vol. 29, No. 5, 1993, pp. 623–630.
- [FORD-71] D. FORD ET J. SCHADÄ, *Atlas of the human brain*, Elsevier Publishing Company, New York, 1971.
- [FORG-65] E. FORGEY, Cluster analysis of multivariate data: efficiency versus interpretability of classifications, Biometrics, Vol. 1, 1965, p. 768.
- [FOX-85] P. FOX, J. PERLMUTTER, ET M. RAICHLE, A stereotactic method of localization for positron emission tomography, Journal of Computer Assisted Tomography, Vol. 9, 1985, pp. 141–152.
- [FOX-94a] P. FOX ET J. LANCASTER, *Neuroscience on the net*, Science, Vol. 266, 1994, pp. 994–996.
- [FRIE-67] H. FRIEDMAN ET J. RUBIN, *On some invariant criteria for grouping data*, Journal of the American Statistical Association, Vol. 62, 1967, pp. 1159–1178.
- [FRIS-89] K. FRISTON, R. PASSINGHAM, J. NUTT, J. HEATHER, G. SAWLE, ET R. FRACKO-WIAK, Localization in PET images: direct fitting of the intercommissural (AC-PC) line, Journal of Cerebral Blood Flow and Metabolism, Vol. 9, 1989, pp. 690–695.
- [FU-81] K. FU ET J. MUI, A survey on image segmentation, Pattern Recognition, Vol. 13, 1981, pp. 3–16.
- [GARZ-96] M. GARZA-JINICH, P. MEER, ET V. MEDINA, Robust retrieval of 3D structures from magnetic resonance images, in International Conference on Pattern Recognition, vol. 3, Vienna, Austria, 1996, pp. 391–395.
- [GEE-93] J. GEE, M. REIVICH, ET R. BAJCSY, *Elastically deformed 3D atlas to match anatomical brain images*, Journal of Computer Assisted Tomography, Vol. 17, No. 2, 1993, pp. 225–236.
- [GEE-95a] J. GEE, L. L. BRIQUER, C. BARILLOT, ET D. HAYNOR, Probabilistic matching of brain images, in International Conference on Information Processing in Medical Imaging, 1995, pp. 113–125.
- [GEE-95b] J. GEE, L. L. BRIQUER, C. BARILLOT, D. HAYNOR, ET R. BAJCSY, *Bayesian* approach to the brain matching problem, in SPIE, vol. 2434, 1995, pp. 145–156.
- [GEIG-91] D. GEIGER ET F. GIROSI, *Parallel and deterministic algorithms for MRFs: surface reconstruction*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 13, 1991, pp. 401–412.

- [GEMA-84] S. GEMAN ET D. GEMAN, Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 6, No. 6, 1984, pp. 721–741.
- [GEMA-87] S. GEMAN, D. GEMAN, ET C. GRAFFIGNE, *Locating texture and object boundaries*, P.A. Devijver and J. Kittler, Springer Verlag, Heidelberg, 1987.
- [GEMA-90] S. GEMAN, D. GEMAN, C. GRAFFIGNE, ET P. DONG, Boundary detection by constrained optimization, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, 1990, pp. 609–628.
- [GERA-95a] T. GÉRAUD, J. MANGIN, I. BLOCH, ET H. MAÎTRE, Segmenting internal structures in 3D MR images of the brain by Markovian relaxation on a watershed based adjacency graph, in IEEE International Conference on Image Processing, vol. 3, Washington DC, U.S.A., 1995, pp. 548–551.
- [GERA-95b] T. GÉRAUD, L. AURDAL, H. MAÎTRE, I. BLOCH, ET C. ADAMSBAUM, Estimation of partial volume effect using spatial context – application to morphometry in cerebral imaging, in IEEE Nuclear Science Symposium and Medical Imaging Conference, San Francisco, California, U.S.A., 1995, pp. –.
- [GERI-92] G. GERIG, O. KÜBLER, R. KIKINIS, ET F. JOLESZ, Nonlinear anisotropic filtering of MRI data, IEEE Transactions on Medical Imaging, Vol. 11, No. 2, 1992, pp. 221– 232.
- [GERI-92b] G. GERIG, J. MARTIN, R. KIKINIS, O. KÜBLER, O. SHENTON, ET F. JOLESZ, Unsupervised tissue type segmentation of 3D dual-echo MR head data, Image and Vision Computing, Vol. 10, 1992, pp. 349–360.
- [GHAN-96] A. GHANEI, H. ZADEH, ET J. WINDHAM, Automatic segmentation of hippocampus from brain MRI using deformable contours, in IEEE International Conference on Image Processing, Lausanne, Switzerland, 1996, pp. 245–248.
- [GIDA-89] B. GIDAS, A renormalization group approach to image processing problems, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 11, No. 2, 1989, pp. 164–180.
- [GLAS-93] C. GLASBEY, *An analysis of histogram-based thresholding algorithms*, CVGIP: Graphical Models and Image Processing, Vol. 55, No. 6, 1993, pp. 532–537.
- [GREI-91] T. GREITZ, C. BOHM, S. HOLTE, ET L. ERIKSSON, A computerized brain atlas: construction, anatomical content and some applications, Journal of Computer Assisted Tomography, Vol. 15, No. 1, 1991, pp. 26–38.
- [GRIM-97] W. GRIMSON, G. ETTINGER, T. KAPUR, M. LEVENTON, W. WELLS, ET R. KIKI-NIS, Utilizing segmented MRI data in image-guided surgery, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 11, No. 8, 1997, pp. 1367–1402.
- [HAAS-67] A. HAAS, G. MATHERON, ET J. SERRA, *Morphologie mathématique et granulométrie en place*, Ann. Mines XI and XII, Vol. 1, 1967, pp. 736–782.

- [HALL-92] L. HALL, A. BENSAID, L. CLARKE, R. VELTHUIZEN, M. SILBIGER, ET J. BEZ-DEK, A comparison of neural network and fuzzy clustering techniques in segmenting magnetic resonance images of the brain, IEEE Transactions on Neural Networks, Vol. 3, No. 5, 1992, pp. 672–682.
- [HAMA-89] M. HAMALAINEN ET J. SARVAS, Realistic conductivity geometry model of the human head for interpretation of neuromagnetic data, IEEE Transactions on Biomedical Engineering, Vol. 36, 1989, pp. 165–171.
- [HANA-80] J. HANAWAY, W. SCOTT, ET C. STROTHER, Atlas of the human brain and the orbit for computed tomography, St. Louis, W.H. Green, Inc., 1980.
- [HARA-85b] R. HARALICK ET L. SHAPIRO, *Survey: image segmentation techniques*, Computer Vision, Graphics, and Image Processing, Vol. 29, 1985, pp. 100–132.
- [HEIM-95] L. HEIMER, *The human brain and spinal cord functional neuroanatomy and dissection guide*, Springer-Verlag, New York, 1995.
- [HEIT-94] F. HEITZ, P. PÉREZ, ET P. BOUTHEMY, Multiscale minimization of global energy functions in some visual recovery problems, CVGIP: Image Understanding, Vol. 59, No. 1, 1994, pp. 125–134.
- [HELD-97] K. HELD, E. KOPS, B. KRAUSE, W. WELLS, R. KIKINIS, ET H. MÜLLER-GÄRTNER, Markov random field segmentation of brain MR images, IEEE Transactions on Medical Imaging, Vol. 16, No. 6, 1997, pp. 878–886.
- [HOHN-92a] K. HÖHNE, M. BOMANS, M. RIEMER, R. SCHUBERT, U. TIEDE, ET W. LIERSE, A volume-based anatomical atlas, IEEE Computer Graphics and Applications, Vol. 12, No. 4, 1992, pp. 72–78.
- [HOHN-92b] K. HÖHNE ET W. HANSON, Interactive 3D segmentation of MRI and CT volumes using morphological operations, Journal of Computer Assisted Tomography, Vol. 16, No. 2, 1992, pp. 285–294.
- [INGR-76] R. INGRAM, A review of anatomical neurology, University Park Press, Baltimore, 1976.
- [JACK-93] E. JACKSON, P. NARAYANA, J. WOLINSKY, ET T. DOYLE, Accuracy and reproducibility in volumetric analysis of multiple sclerosis lesions, Journal of Computer Assisted Tomography, Vol. 17, 1993, pp. 200–205.
- [JAGG-97] C. JAGGI, S. RUAN, J. FADILLI, ET D. BLOYET, Approche Markovienne pour la segmentation des tissus cérébraux en IRM, in Colloque sur le Traitement du Signal et des Images (GRETSI), Grenoble, France, 1997, pp. 327–330.
- [JOHN-93] K. JOHNSON, M. KIJEWSKI, J. BECKER, B. GARADA, A. SATLIN, ET B. HOL-MAN, Quantitative brain SPECT in alzheimer's disease and normal aging, J Nucl Med, Vol. 34, No. 11, 1993, pp. 2044–2048.
- [JOLI-92] J. JOLION ET A. MONTANVERT, *The adapted pyramid: a framework for 2D image analysis*, CVGIP: Image Understanding, Vol. 55, No. 3, 1992, pp. 339–348.

- [JOLI-93] M. JOLIOT ET B. MAZOYER, Three-dimensional segmentation and interpolation of magnetic resonance brain images, IEEE Transactions on Medical Imaging, Vol. 12, No. 2, 1993, pp. 269–277.
- [KAMB-95] M. KAMBER, R. SHINGHAL, D. COLLINS, G. FRANCIS, ET A. EVANS, Modelbased 3D segmentation of multiple sclerosis lesions in megnetic resonance brain images, IEEE Transactions on Medical Imaging, Vol. 14, 1995, pp. 442–453.
- [KANA-80] T. KANADE, *Region segmentation: signal vs semantics*, Computer Graphics, and Image Processing, Vol. 13, No. 4, 1980, pp. 279–297.
- [KARS-90] N. KARSSEMEIJER, A relaxation method for image segmentation using a spatially dependent stochastic model, Pattern Recognition Letters, Vol. 11, No. 1, 1990, pp. 13–23.
- [KASS-88] M. KASS, A. WITKIN, ET D. TERZOPOULOS, *Snakes: active contour models*, International Journal of Computer Vision, Vol. 1, No. 4, 1988, pp. 321–331.
- [KATO-92] Z. KATO, J. ZERUBIA, ET M. BERTHOD, Satellite image classification using a modified Metropolis dynamics, in IEEE International Conference on Acoustics, Speech, and Signal Processing, San Francisco, California, U.S.A., 1992.
- [KATO-93] Z. KATO, M. BERTHOD, ET J. ZERUBIA, Multiscale Markov random field models for parallel image classification, in International Conference on Computer Vision, Berlin, Germany, 1993, pp. 253–257.
- [KELL-95] J. KELLER ET X. WANG, Comparison of spatial relation definitions in computer vision, in ISUMA-NAAFIPS, College Park, U.S.A., 1995, pp. 679–684.
- [KEND-84] D. KENDALL, *Shape-manifolds, procrustean metrics, and complex projective spaces,* Bulletins of London Mathematical Society, Vol. 18, 1984, pp. 81–121.
- [KIKI-92] R. KIKINIS, M. SHENTON, ET G. G. ET AL., Routine quantitative analysis of brain and cerebrospinal fluid spaces with MR imaging, Journal of Magnetic Resonance Imaging, Vol. 2, 1992, pp. 619–629.
- [KIKI-96] R. KIKINIS, M. SHENTON, D. IOSIFESCU, ET R. M. ET AL., A digital brain atlas for surgical planning, model-driven segmentation, and teaching, IEEE Transactions on Visualization and Computer Graphics, Vol. 2, No. 3, 1996, pp. 232–241.
- [KIM-93] I. KIM ET H. YANG, Efficient image labelling based on Markov random field and error backpropagation network, Pattern Recognition, Vol. 26, No. 11, 1993, pp. 1695– 1707.
- [KIM-94] —, A systematic way for region-based image segmentation based on Markov random field model, Pattern Recognition Letters, Vol. 15, 1994, pp. 969–976.
- [KLIR-92] G. KLIR ET B. PARVIZ, Probability-possibility transformations: a comparison, International Journal on General Systems, Vol. 21, 1992, pp. 291–310.
- [KOHN-91] M. KOHN, N. TANNA, G. HERMAN, S. RESNICK, P. MOZLEY, R. GUR, A. ALAVI, R. ZIMMERMAN, ET R. GUR, Analysis of brain and cerebrospinal fluid volumes with MR imaging: part i methods, reliability, and validation, Radiology, Vol. 178, No. 1, 1991, pp. 115–122.

- [KONG-89] T. KONG ET A. ROSENFELD, *Digital topology: introduction and survey*, Computer Vision, Graphics, and Image Processing, Vol. 48, 1989, pp. 357–393.
- [KRET-86] H. KRETSCHMANN ET W. WEINRICH, *Neuroanatomy and cranial computed tomo*graphy, Georg Thieme Verlag, Stuttgart, 1986.
- [KRIS-93] R. KRISHNAPURAM ET J. KELLER, *A possibilistic approach to clustering*, IEEE Transactions on Fuzzy Systems, Vol. 1, No. 2, 1993, pp. 98–110.
- [KRIS-93b] R. KRISHNAPURAM, J. KELLER, ET Y. MA, Quantitative analysis of properties and spatial relations of fuzzy image regions, IEEE Transactions on Fuzzy Systems, Vol. 1, No. 3, 1993, pp. 222–233.
- [KUND-90] A. KUNDU, Local segmentation of biomedical images, Computerized Medical Imaging and Graphics, Vol. 14, 1990, pp. 173–183.
- [KWAN-96] R. KWAN, A. EVANS, ET G. PIKE, An extensible MRI simulator for post-processing evaluation, in Visualization in Biomedical Computing, vol. 1131, 1996, pp. 135–140.
- [LAKS-89] S. LAKSHMANAN ET H. DERIN, Simultaneous parameter estimation and segmentation of Gibbs random fields using simulated annealing, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 11, No. 8, 1989, pp. 799–813.
- [LAKS-93] —, *Gaussian Markov random fields at multiple resolutions*, R. Chellappa and A. Jain, Academic Press, 1993, pp. 131–157.
- [LANC-95] J. LANCASTER, T. GLASS, B. LANKIPALLI, H. DOWNS, H. MAYBERG, ET P. FOX, A modality-independent approach to spatial normalization of tomographic images of the human brain, Human Brain Mapping, Vol. 3, 1995, pp. 209–223.
- [LANG-97b] S. LANGLOIS, M. DESVIGNES, ET J. CONSTANS, Imagerie par résonance magnétique: correction des non linéarités des gradients de champ, in Colloque sur le Traitement du Signal et des Images (GRETSI), Grenoble, France, 1997, pp. 339–342.
- [LEGO-94] R. L. GOFF, V. FROUIN, J. MANGIN, ET B. BENDRIEM, Use of segmented MR images for brain attenuation correction in PET, in SPIE Medical Imaging: Image Processing, vol. 2167, 1994, pp. 725–736.
- [LEMO-91] D. LEMOINE, C. BARILLOT, B. GIBAUD, ET E. PASQUALINI, An anatomical-based 3D registration of multimodality and atlas data in surgery, in International Conference on Information Processing in Medical Imaging, 1991, p. 188.
- [LI-93] C. LI, B. GOLDGOF, ET L. HALL, Knowledge-based classification and tissue labeling of MR images of human brain, IEEE Transactions on Medical Imaging, Vol. 12, No. 4, 1993, pp. 740–750.
- [LI-95] W. LI, M. MORRISON, ET Y. ATTIKIOUZEL, Unsupervised segmentation of dualecho MR images by a sequentially learned Gaussian mixture model, in IEEE International Conference on Image Processing, vol. 3, Washington DC, U.S.A., 1995, pp. 576–579.
- [LIAN-93] Z. LIANG, Tissue classification and segmentation of MR images, IEEE Engineering in Medicine and Biology, Vol. 13, 1993, pp. 81–85.

- [LIAN-94] Z. LIANG, J. MACFALL, ET D. HARRINGTON, *Parameter estimation and tissue segmentation from multispectral MR images*, IEEE Transactions on Medical Imaging, Vol. 13, No. 3, 1994, pp. 441–449.
- [LIM-89] K. LIM ET A. PFEFFERBAUM, Segmentation of MR brain images into cerebro-spinal fluid spaces, white and gray matter, Journal of Computer Assisted Tomography, Vol. 13, 1989, pp. 588–593.
- [LUDW-56] E. LUDWIG ET J. KLINGLER, *Atlas cerebri humani*, Little, Brown & Company, Boston, 1956.
- [LUET-93] M. LUETTGEN, W. KARL, A. WILLSKY, ET R. TENNEY, Multiscale representations of Markov random fields, in IEEE International Conference on Acoustics, Speech, and Signal Processing, vol. 5, Minneapolis, U.S.A., 1996, pp. 41–44.
- [LUND-95] A. LUNDERVOLD ET G. STORVIK, Segmentation of brain parenchyma and cerebrospinal fluid in multispectral magnetic resonance images, IEEE Transactions on Medical Imaging, Vol. 14, 1995, pp. 339–349.
- [MAES-95] F. MAES, D. VANDERMEULEN, P. SUETENS, ET G. MARCHAL, Computed-aided interactive object delineation using an intelligent paintbrush technique, in International Conference on Computed Vision, Virtual Reality and Robotics in Medicine, Nice, France, 1995, pp. 77–83.
- [MANG-95] J. MANGIN, *Mise en correspondance d'images médicales 3D multi-modalités multiindividus pour la corrélation anatomo-fonctionnelle cérébrale*, Thèse de doctorat, École Nationale Supérieure des Télécommunications, Paris, France, 1995.
- [MANG-95a] J. MANGIN, V. FROUIN, I. BLOCH, J. REGIS, ET J. LOPEZ-KRAHE, From 3d magnetic resonance images to structural representations of the cortex topography using topology preserving deformations, Journal of Mathematical Imaging and Vision, Vol. 5, 1995, pp. 297–318.
- [MARD-96] K. MARDIA, T. HAINSWORTH, ET J. KIRKBRIDE, Hierarchical Bayesian classification of multimodal medical images, in Proceedings of IEEE MMBIA, 1996, pp. 53– 63.
- [MARR-80] D. MARR ET E. HILDRETH, *Theory of edge detection, in* Royal Society of London, vol. 207, 1980, pp. 187–217.
- [MARR-87] J. MARROQUIN, S. MITTER, ET T. POGGIO, Probabilistic solution of ill-posed problems in computational vision, Journal of the American Statistical Association, Vol. 82, 1987, pp. 76–89.
- [MART-96] J. MARTIN, *Neuroanatomy text and atlas*, Appleton & Lange, Stanford, 1996.
- [MATH-93] C. MATHIEU, Segmentation d'images par pyramides souples: application à l'imagerie médicale multi-dimensionnelle, Thèse de doctorat, INSA, Lyon, France, 1993.
- [MATS-78] T. MATSUI ET A. HIRANO, *An atlas of the human brain for computerized tomography*, Igako-Shoin, Tokyo, 1978.

- [MATZ-67] H. MATZKE ET F. FOLTZ, *Synopsis of neuroanatomy*, Oxford University Press, New York, 1967.
- [MCCL-95] K. MCCLAIN, Y. ZHU, ET J. HAZLE, *Selection of MR images for automated segmentation*, Journal of Magnetic Resonance Imaging, Vol. 5, No. 5, 1995, pp. 485–492.
- [MCIN-96] T. MCINERNEY ET D. TERZOPOULOS, Deformable models in medical image analysis, in Mathematical Methods in Biomedical Image Analysis, San Francisco, California, U.S.A., 1996, pp. 171–180.
- [MCQU-67] J. MCQUEEN, Some methods for classification and analysis of multivariate observations, in Berkeley Symposium on Mathematics, Statistics, and Probability, 1967, pp. 281–297.
- [MEER-89] P. MEER, Stochastic image pyramids, Computer Vision, Graphics, and Image Processing, Vol. 45, 1989, pp. 269–294.
- [METR-53] N. METROPOLIS, A. ROSENBLUTH, M. ROSENBLUTH, A. TELLER, ET E. TEL-LER, *Equation of state calculations by fast computing machines*, Journal of Chemical Physics, Vol. 21, 1953, pp. 1087–1092.
- [MITC-94] J. MITCHELL, S. KARLIK, D. LEE, ET A. FENSTER, Computer-assisted identification and quantification of multiple sclerosis lesions in MR imaging volumes in the brain, Journal of Magnetic Resonance Imaging, Vol. 4, 1994, pp. 197–208.
- [MIYA-94] K. MIYAJIMA ET A. RALESCU, *Spatial organization in 2D images, in* IEEE International Conference on Fuzzy Systems, Orlando, Florida, U.S.A., 1994, pp. 100–105.
- [MIYA-94b] —, Spatial organization in 2D segmented images: representation and recognition of primitive spatial relations, Fuzzy Sets and Systems, Vol. 65, 1994, pp. 225–236.
- [MONG-87] O. MONGA, *An optimal growing algorithm for image segmentation*, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 1, No. 3, 1991, pp. 351–376.
- [MONG-92] O. MONGA, S. BENAYOUN, ET O. FAUGERAS, Using third order derivatives to extract ridge lines in 3D images, in IEEE International Conference on Computer Vision and Pattern Recognition, Urbana Champaign, Illinois, U.S.A., 1992, pp. –.
- [MONT-91] A. MONTANVERT, P. MEER, ET A. ROSENFELD, *Hierarchical image analysis using irregular tessellations*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 13, 1991, pp. 307–316.
- [MOSH-91] M. MOSHFEGHI, Elastic matching of multimodality medical images, IEEE Transactions on Image Processing, Vol. 53, No. 3, 1991, pp. 271–282.
- [MOSH-94] M. MOSHFEGHI, S. RAGANATH, ET K. NAWYN, *3D elastic matching of volumes*, IEEE Transactions on Image Processing, Vol. 3, No. 2, 1994, pp. 128–138.
- [MULL-92] J. MULLIKIN, *The vector distance transform in two and three dimensions*, CVGIP: Graphical Models and Image Processing, Vol. 54, No. 6, 1992, pp. 526–535.

- [NELS-94] S. NELSON, A. NALBANDIAN, E. PROCTOR, ET D. VIGNERON, Registration of images from sequential MR studies of the brain, Journal of Magnetic Resonance Imaging, Vol. 4, 1994, pp. 877–883.
- [NIEL-98] F. NIELSEN ET L. HANSEN, Neuroinformatics based on VRML (under submission), in International Conference on Functional Mapping of the Human Brain, Montreal, Canada, 1998.
- [NIEU-88] R. NIEUWENHUYS, J. VOOGD, ET C. VAN HUIJZEN, *The human central nervous* system a synopsis and atlas, Springer-Verlag, 1988.
- [NOBA-96] C. NOBACK, N. STROMINGER, ET R. DEMAREST, *The human nervous system structure and function*, Williams & Wilkins, Philadelphia, 1996.
- [NORT-98] C. NORTH, *Robust, end-user programmable, multiple-window coordination, in* ACM Computer-Human Interaction Conference, Los Angeles, California, U.S.A., 1998.
- [ORTE-85] D. ORTENDAHL, N. HYLTON, L. KAUFMAN, ET L. CROOKS, *Tissue characteriza*tion using intrinsic NMR parameters and a hierarchical processing algorithm, IEEE Transactions on Nuclear Science, Vol. 32, No. 1, 1985, pp. 875–879.
- [OTAK-95] N. OTAKI, T. PAUS, D. D'AVIRRO, D. GUTMANS, D. MACDONALD, Z. CARA-MANOS, F. TOMAIOULO, ET A. EVANS, Volumetric analysis of the human cingulate, paracingulate and superior rostral sulci, Soc. Neurosci. Abstracts, Vol. 21, No. 1, 1995, p. 154.
- [OZKA-93] M. ÖZKAN, B. DAWANT, ET R. MACIUNAS, Neural-network based segmentation of multi-modal medical images: a comparative and prospective study, IEEE Transactions on Medical Imaging, Vol. 12, No. 3, 1993, pp. 534–544.
- [PAL-93] N. PAL ET S. PAL, A review on image segmentation techniques, Pattern Recognition, Vol. 26, No. 9, 1993, pp. 1277–1294.
- [PAL-93b] N. PAL, J. BEZDEK, ET E. TSAO, Generalized clustering networks and Kohonen's self-organizing scheme, IEEE Transactions on Neural Networks, Vol. 4, 1993, pp. 549–557.
- [PAPP-92] T. PAPPAS, An adaptative clustering algorithm for image segmentation, IEEE Transactions on Signal Processing, Vol. 40, No. 4, 1992, pp. 901–914.
- [PARI-88] G. PARISI, Statistical Field Theory, Addison–Wesley, 1988.
- [PAVL-77] T. PAVLIDIS, *Structural pattern recognition*, Springer Verlag, Heidelberg, 1977.
- [PEDR-90] W. PEDRYCZ, Fuzzy sets in pattern recognition: methodology and methods, Pattern Recognition, Vol. 23, No. 1, 1990, pp. 121–146.
- [PELI-89] A. PELIZZARI, G. CHEN, D. SPELBRING, R. WEICHSELBAUM, ET C. CHEN, Accurate three-dimensional registration of CT, PET and/or MR images of the brain, Journal of Computer Assisted Tomography, Vol. 13, No. 1, 1989, pp. 20–26.
- [PERE-93] P. PÉREZ ET F. HEITZ, Restriction d'un champ markovien sur un graphe et analyse d'images multirésolution, in Colloque sur le Traitement du Signal et des Images (GRETSI), Juan Les Pins, France, 1995, pp. 5–8.

- [PERO-90] P. PERONA ET J. MALIK, Scale-space and edge detection using anisotropic diffusion, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, No. 7, 1990, pp. 629–639.
- [PHAM-97] D. PHAM, J. PRINCE, C. XU, ET A. DAGHER, An automated technique for statistical characterization of brain tissues in magnetic resonance imaging, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 11, No. 8, 1997, pp. 1189–1211.
- [PHIL-95] W. PHILLIPS, R. VELTHUIZEN, S. PHUPHANICH, S. VILORIA, L. HALL, L. CLARKE, ET M. SILBIGER, Application of fuzzy c-means segmentation technique for tissue differentiation in MR images of a hemorrhagic glioblastoma multiforme, Journal of Magnetic Resonance Imaging, Vol. 13, No. 2, 1995, pp. 277–290.
- [POWE-64] R. POWELLS, An efficient method for finding the minimum of a function of several variables without calculating derivatives, Computer Journal, Vol. 7, 1964, pp. 155–163.
- [PRES-88] W. PRESS, B. FLANNERY, S. TEUKOLSKY, ET W. VETTERLING, Numerical recipies in C, Cambridge University Press, 1988.
- [RAFF-94] U. RAFF, A. SCHERZINGER, P. VARGAS, ET J. SIMON, Quantitation of gray matter, white matter, and cerebrospinal fluid from spin-echo magnetic resonance images using an artificial neural network technique, Medical Physics, Vol. 21, No. 12, 1994, pp. 1933–1942.
- [RAMA-91] S. RAMAN, S. SARKAR, ET K. BOYER, Tissue boundary refinement in magnetic resonance images using contour-based scale space matching, IEEE Transactions on Medical Imaging, Vol. 10, No. 2, 1991, pp. 109–121.
- [REDD-97] W. REDDICK, J. GLASS, E. COOK, T. ELKIN, ET J. DEATON, Automated segmentation and classification of multispectral magnetic resonance images of brain using artificial neural networks, IEEE Transactions on Medical Imaging, Vol. 16, No. 6, 1987, pp. 911–918.
- [REGA-93] C. REGAZZONI, F. ARDUINI, ET G. VERNAZZA, A multilevel GMRF-based approach to image segmentation and restoration, Signal Processing, Vol. 34, No. 1, 1993, pp. 43–67.
- [RHEE-94] F. RHEE ET R. KRISHNAPURAM, Generation of fuzzy rules involving spatial relations for computer vision, in IEEE International Conference on Fuzzy Systems, Orlando, Florida, U.S.A., 1994, pp. 2014–2019.
- [ROBE-70] M. ROBERTS ET J. HANAWAY, *Atlas of the human brain in section*, Lea & Febiger, Philadelphia, 1970.
- [ROHE-75] Y. ROHEN, *Funktionelle Anatomie des Nervensystems*, F.K. Schattauerverlag, Stuttgart, 1975.
- [ROYA-97] N. ROYACKKERS, Modélisation et reconnaissance des sillons du cortex cérébral humain, Thèse de doctorat, Université de Caen, France, 1997.

- [RUPR-95] D. RUPRECHT ET H. MULLER, A framework for scattered data interpolation, Springer-Verlag, Vienna, 1995.
- [SAHA-94a] P. SAHA, B. CHAUDHURI, B. CHANDA, ET D. MAJUMDER, Topology preservation in 3D digital space, Pattern Recognition, Vol. 27, No. 2, 1994, pp. 295–300.
- [SAND-94a] S. SANDOR ET R. LEAHY, Matching deformable atlas models to preprocessed magnetic resonance brain images, in IEEE International Conference on Image Processing, Austin, Texas, U.S.A., 1994, pp. 686–690.
- [SAND-94c] \_\_\_\_\_, A 3D morphology algorithm for automated labelling of the cortex in magnetic resonance brain images, in AAAI Symposium on Medical Applications in Computer Vision, Stanford University, Canada, 1994, pp. –.
- [SANT-93] P. SANTAGO ET H. GAGE, Quantification of MR brain images by mixture density and partial volume modeling, IEEE Transactions on Medical Imaging, Vol. 12, No. 3, 1993, pp. 566–574.
- [SAPO-90] G. SAPORTA, Probabilités, analyse de données et statistique, Technip, Paris, 1990.
- [SCHI-94a] T. SCHIEMANN, K. H. HÖHNE, C. KOCH, A. POMMERT, M. RIEMER, R. SCHU-BERT, ET U. TIEDE, Interpretation of tomographic images using automatic atlas lookup, in SPIE Visualization in Biomedical Computing, vol. 2359, 1994, pp. 457–465.
- [SCHM-94] M. SCHMITT ET J. MATTIOLI, Morphologie mathématique, Masson, Paris, 1994.
- [SEND-94] M. SENDA, I. KANNO, Y. YONEKURA, ET H. F. ET AL., Comparison of anatomical standardization methods regarding the sensorimotor foci localization and betweensubject variation in H<sup>15</sup><sub>2</sub>O PET activation, a three-center collaboration study, Annals of Nuclear Medicine, Vol. 8, No. 3, 1994, pp. 201–207.
- [SERR-82] J. SERRA, *Image analysis and mathematical morphology*, Academic Press, London, 1982.
- [SERR-88] —, Image analysis and mathematical morphology, part II: theoretical advances, Academic Press, London, 1988.
- [SHEN-95] M. SHENTON, R. KIKINIS, R. MCCARLEY, P. SAIVIROONPORN, H. HOKAMA, A. ROBATINO, D. METCALF, C. WIBLE, C. PORTAS, D. IOSIFESCU, R. DON-NINO, ET F. JOLESZ, *Harvard brain atlas: a teaching and visualizing tool, in* Biomedical Visualization, Washington DC, U.S.A., 1995, pp. 10–17.
- [SHIM-93] J. SHIMONY ET H. MORRIS, An algorithm for grey/white matter segmentation of MRI brain images, in SPIE Mathematical Methods in Medical Imaging II, vol. 2035, 1993, pp. 89–94.
- [SIGE-93] M. SIGELLE, Champs de Markov en traitement d'images et modèles de la physique statistique: applications en relaxation d'images de classification, Thèse de doctorat, École Nationale Supérieure des Télécommunications, Paris, France, 1993.
- [SIGE-97] —, Simultaneous image restoration and hyperparameter estimation for incomplete data by a cumulant analysis (*RR-3249*), rapp. tech., INRIA, France, 1997.

- [SINE-63] R. SINELNIKOW, Atlas of the human anatomy nervous system, organs of special senses and endocrynology, vol. 3, Gosudarstvenoe Izdatelstvo Medicinskoy Literaturi, Moskva, 1963.
- [SLAV-97] K. SLAVIN, *The visible human project*, Surgical Neurology, Vol. 48, No. 6, 1997, pp. 638–639.
- [SOLT-96] H. SOLTANIAN-ZADEH, J. WINDHAM, ET D. PECK, *Optimal linear transformation* for MRI feature extraction, in Proceedings of IEEE MMBIA, 1996, pp. 64–73.
- [STAI-97] L. STAIB, A. CHAKRABORTY, ET J. DUNCAN, An integrated approach for locating neuroanatomical structure from MRI, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 11, No. 8, 1997, pp. 1247–1269.
- [SUBS-95] G. SUBSOL, Construction automatique d'atlas anatomiques morphométriques à partir d'images médicales tridimensionnelles, Thèse de doctorat, École Centrale de Paris, France, 1995.
- [SUET-93] P. SUETENS, E. BELLON, D. VANDERMEULEN, M. SMET, G. MARCHAL, J. NUYTS, ET L. MORTELMANS, *Image segmentation: methods and applications in diagnostic radiology and nuclear medicine*, European Journal of Radiology, Vol. 17, 1993, pp. 14–21.
- [SUZU-91] H. SUZUKI ET J. TORIWAKI, Automatic segmentation of head MRI images by knowledge guided thresholding, Computerized Medical Imaging and Graphics, Vol. 15, 1991, pp. 233–240.
- [SZEL-93] R. SZELISKI ET S. LAVALLÉE, Matching 3D anatomical surfaces with non-rigid deformations using octree-splines, in SPIE: Geometric Methods in Computer Vision II, 1993, pp. 306–315.
- [TAKA-77] M. TAKASE, A. TOKUNAGA, K. OTANI, ET T. HORIE, *Atlas of the human brain* for computed tomography based on the glabella-inion line, Neuroradiology, Vol. 14, 1977, pp. 73–79.
- [TALA-67] J. TALAIRACH, G. SZIKLA, ET P. TOURNOUX, Atlas d'anatomie stéréotaxique du télencéphale, Masson, Paris, 1967.
- [TALA-88] J. TALAIRACH ET P. TOURNOUX, *Co-planar stereotaxic atlas of the human brain*, Georg Thieme Verlag, Stuttgart, 1988.
- [TALA-93] —, Referentially oriented cerebral MRI anatomy: atlas of stereotaxic anatomical correlations for gray and white matter, Georg Thieme Verlag, Stuttgart, 1993.
- [TALM-77] L. TALMAGE, *The neuroanatomic basis for clinical neurology*, McGraw-Hill, New York, 1977.
- [TAXT-94] T. TAXT ET A. LUNDERVOLD, *Multispectral analysis of the brain using magnetic resonance imaging*, IEEE Transactions on Medical Imaging, Vol. 13, No. 3, 1994, pp. 470–481.
- [TEK-95] H. TEK ET B. KIMIA, Automatic volumetric segmentation of three-dimensional medical images, in Computer Assisted Radiology, Berlin, Germany, 1995, pp. 164–170.

- [TERZ-88] D. TERZOPOULOS, A. WITKIN, ET M. KASS, Contraints on deformable models: recovering 3D shape and nonrigid motion, Artificial Intelligence, Vol. 36, No. 1, 1988, pp. 91–123.
- [THIR-93] J. THIRION ET A. GOURDON, *The marching lines algorithm: new results and proofs* (*RR-1881*), rapp. tech., INRIA, 1993.
- [THOM-96a] P. THOMPSON, C. SCHWARTZ, ET A. TOGA, *High-resolution random mesh algorithms for creating a probabilistic 3D surface atlas of the human brain*, Neuroimage, Vol. 3, 1996, pp. 19–34.
- [THOM-96b] P. THOMPSON ET A. TOGA, A surface-based technique for warping threedimensional images of the brain, IEEE Transactions on Medical Imaging, Vol. 15, No. 4, 1996, pp. 402–417.
- [THUR-93] L. THURFJELL, C. BOHM, T. GREITZ, ET L. ERIKSSON, Transformations and algorithms in a computerized brain atlas, IEEE Transactions on Nuclear Science, Vol. 40, No. 4, 1993, pp. 1187–1191.
- [TIED-93] U. TIEDE, M. BOMANS, K. HÖHNE, M. RIEMER, T. SCHIEMANN, R. SCHUBERT, ET W. LIERSE, A computerized three-dimensional atlas of the human skull and brain, AJNR, Vol. 14, 1993, pp. 551–559.
- [TOGA-93] A. TOGA, A. JONES, J. ROTHFELD, R. WOODS, B. PAYNE, C. HUANG, J. MAZ-ZIOTTA, ET R. CAI, *Anatomic variability as measured with a 3D reconstructed talairach atlas, in* JAPON, K. U. et al., ed., Elsevier Science, 1993, pp. 449–457.
- [TOH-96] M. TOH, R. FALK, ET J. MAIN, Interactive brain atlas with the visible human project data: development methods and techniques, Radiographics, Vol. 16, No. 5, 1996, pp. 1201–1206.
- [TRUE-76] R. TRUEX ET M. CARPENTER, *Human neuroanatomy*, Williams & Wilkins, Baltimore, 1976.
- [TSAI-95] C. TSAI, B. MANJUNATH, ET R. JAGADEESAN, Automated segmentation of brain *MR images*, Pattern Recognition, Vol. 28, No. 12, 1995, pp. 1825–1837.
- [UNDR-97] P. UNDRILL, K. DELIBASIS, ET G. CAMERON, An application of genetic algorithms to geometric model-guided interpretation of brain anatomy, Pattern Recognition, Vol. 30, No. 2, 1997, pp. 217–227.
- [VAND-91] D. VANDERMEULEN, Methods for registration, interpolation and interpretation of three-dimensional medical image data for use in 3D modeling and therapy planning, Thèse de doctorat, Katholieke Universiteit Leuven, Belgique, 1991.
- [VAND-93] D. VANDERMEULEN, R. VERBEECK, L. BERBEN, P. SUETENS, ET G. MARCHAL, Continuous voxel classification by stochastic relaxation – theory and application to MR-imaging and MR-angiography, in International Conference on Information Processing in Medical Imaging, Flagstaff, Arizona, U.S.A., 1993, pp. 487–506.
- [VANE-93] P. VAN DEN ELSEN, E. POL, ET M. VIERGEVER, Medical image matching: a review with classification, IEEE Engineering in Medicine and Biology, Vol. 12, No. 1, 1993, pp. 26–38.

- [VANL-87] P. VAN LAARHOVEN ET E. AARTS, *Simulated annealing: theory and applications*, Reidel Publishing, 1987.
- [VANN-85] M. VANNIER, R. BUTTERFIELD, D. JOURDAN, W. MURPHY, R. LEVITT, ET M. GADO, Multispectral analysis of magnetic resonance images, Radiology, Vol. 154, No. 1, 1985, pp. 221–224.
- [VANN-88] M. VANNIER, C. SPEIDEL, ET D. RICKMAN, Magnetic resonance imaging multispectral tissue classification, News of Physiological Science, Vol. 3, 1988, pp. 148– 154.
- [VANN-91] M. VANNIER, T. PILGRAM, C. SPEIDEL, L. NEUMANN, D. RICKMAN, ET L. SCHERTZ, Validation of magnetic resonance imaging (MRI) multispectral tissue classification, Computerized Medical Imaging and Graphics, Vol. 15, 1991, pp. 217– 223.
- [VEHK-95] T. VEHKOMÄKI, G. GERIG, ET G. SZÉLEZKY, Segmentation of volume data by contour fragment grouping, in Computer Assisted Radiology, Berlin, Germany, 1995, pp. 131–136.
- [VEIJ-94] A. VEIJANEN, Unsupervised image segmentation using an unlabeled region process, Pattern Recognition, Vol. 27, No. 6, 1994, pp. 841–852.
- [VELT-95] R. VELTHUIZEN, S. PHUPHANICH, L. CLARKE, L. HALL, A. BENSAID, J. AR-RINGTON, ET M. SILBIGER, Unsupervised tumor volume measurement using magnetic resonance brain images, Journal of Magnetic Resonance Imaging, Vol. 5, No. 5, 1995, pp. 594–605.
- [VERA-95] L. VÉRARD, P. ALLAIN, J. TRAVÈRE, S. RUAN, ET D. BLOYET, 3D brain structures extraction using fully automated MRI segmentation, in Colloque sur le Traitement du Signal et des Images (GRETSI), vol. 2, 1995, pp. 1213–1216.
- [VERA-97] L. VÉRARD, P. ALLAIN, J. TRAVÈRE, J. BARON, ET D. BLOYET, Fully automatic identification of AC and PC landmarks on brain MRI using scene analysis, IEEE Transactions on Medical Imaging, Vol. 16, No. 5, 1997, pp. 610–616.
- [VERW-91] B. VERWER, *Local distances for distance transformations in two or three dimensions*, Pattern Recognition Letters, Vol. 12, No. 11, 1991, pp. 671–682.
- [VINC-91] L. VINCENT ET P. SOILLE, Watersheds in digital spaces: an efficient algorithm based on immersion simulations, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 13, No. 6, 1991, pp. 583–598.
- [VINC-92] L. VINCENT, Morphological algorithms, in Mathematical Morphology in Image Processing, E. Dougherty, ed., Marcel Dekker, 1992, pp. 255–288.
- [WAKS-90] A. WAKS ET O. TRETIAK, *Recognition of regions in brain sections*, Computerized Medical Imaging and Graphics, Vol. 14, 1990, pp. 341–352.
- [WANG-94a] Y. WANG ET T. LEI, A new stochastic model-based image segmentation technique for MR image, in IEEE International Conference on Image Processing, vol. 2, Austin, Texas, U.S.A., 1994, pp. 182–186.

- [WATS-77] C. WATSON, *Basic human neuroanatomy an introductory atlas*, Little, Brown & Company, Boston, 1977.
- [WILL-75] P. WILLIAMS ET R. WARWICK, *Functional neuroanatomy of man*, W.B. Saunders, Philadelphia, 1975.
- [WOLF-72] G. WOLF-HEIDEGGER, Atlas of systematic human anatomy systema nervosumsystema vasorum, S. Karger, New YorkNew York, 1972.
- [WOOD-93a] R. WOODS, J. MAZZIOTTA, ET S. CHERRY, MRI-PET registration with automated algorithm, Journal of Computer Assisted Tomography, Vol. 17, No. 4, 1993, pp. 536– 546.
- [WOOD-93b] —, *Automated registration of MRI and PET studies*, Journal of Cerebral Blood Flow and Metabolism, Vol. 13, No. suppl. 1, 1993, p. 842.
- [WRIG-59] M. WRIGHT, *Fibre systems of the brain and spinal cord*, Witwatersrand University Press, Johannesburg, 1959.
- [XUAN-95] J. XUAN, T. ADALI, ET Y. WANG, Segmentation of magnetic resonance brain image: integrating region growing and edge detection, in IEEE International Conference on Image Processing, Washington DC, U.S.A., 1995, pp. 544–547.
- [YAGE-91] R. YAGER, *Connectives and quantifiers in fuzzy sets*, Fuzzy Sets and Systems, Vol. 40, 1991, pp. 39–75.
- [YAN-95] M. YAN ET J. KARP, An adaptative bayesian approach to three-dimensional MR brain segmentation, in International Conference on Information Processing in Medical Imaging, 1995, pp. 201–213.
- [YAN-96] B. YAN ET J. KELLER, A heuristic simulated annealing algorithm of learning possibility measures for multisource decision making, Fuzzy Sets and Systems, Vol. 77, 1996, pp. 87–109.
- [ZADE-65] L. ZADEH, *Fuzzy sets*, Information Controls, Vol. 8, 1965, pp. 338–353.
- [ZADE-78] —, *Fuzzy sets as a basis for a theory of possibility*, Fuzzy Sets and Systems, Vol. 1, 1978, pp. 3–28.
- [ZERU-93] J. ZERUBIA ET R. CHELAPPA, Mean field annealing using compound Gauss-Markov random field for edge detection and image estimation, IEEE Transactions on Neural Networks, Vol. 4, No. 4, 1993, pp. 703–709.
- [ZERU-94] J. ZERUBIA, Z. KATO, ET M. BERTHOD, Multi-temperature annealing: a new approach for the energy minimization of hierarchical Markov random field models, in International Conference on Pattern Recognition, Jerusalem, Israel, 1994.
- [ZIJD-93] A. ZIJDENBOS, B. DAWANT, ET R. MARGOLIN, Measuring reliability and reproductivity in manual and semi-automatic MRI segmentation, in IEEE International Conference on Engineering in Medicine and Biology Society, 1993, pp. 162–163.
- [ZORO-95] R. ZOROOFI, Y. SATO, S. TAMURA, H. NAITO, ET L. TANG, An improved method for MRI artifact correction due to translation motion in the imaging plane, IEEE Transactions on Medical Imaging, Vol. 14, No. 3, 1995, pp. 471–479.

- [ZUCK-76] S. ZUCKER, *Region growing: childhood and adolescence*, Computer Graphics, and Image Processing, Vol. 5, No. 3, 1976, pp. 382–399.
- [ZULE-77] S. ZULEGER ET Y. STAUBESAND, *Atlas of the central nervous system in sectional planes*, Urban and Schwarzenberg, Baltimore, 1977.
- [ZWIC-87] R. ZWICK, E. CARLSTEIN, ET D. BUDESCU, Measures of similarity among fuzzy concepts: a comparative analysis, International Journal of Approximate Reasoning, Vol. 1, 1987, pp. 221–242.

## **Table des figures**

1.2Vue extrudée de l'encéphale201.3Noyau caudé211.4Aire accumbens211.5Pallidum221.6Thalamus221.7Hypothalamus231.8Commissure antérieure241.9Claustrum252.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 34
1.3Noyau caudé211.4Aire accumbens211.5Pallidum221.6Thalamus221.7Hypothalamus231.8Commissure antérieure241.9Claustrum252.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 35
1.4Aire accumbens211.5Pallidum221.6Thalamus221.7Hypothalamus231.8Commissure antérieure241.9Claustrum252.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 35
1.5Pallidum221.6Thalamus221.7Hypothalamus231.8Commissure antérieure241.9Claustrum252.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 35
1.6Thalamus221.7Hypothalamus231.8Commissure antérieure241.9Claustrum252.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 35
1.7Hypothalamus231.8Commissure antérieure241.9Claustrum252.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 35
1.8       Commissure antérieure       24         1.9       Claustrum       25         2.1       Planche axiale de $xavT_1$ 34         2.2       Planche coronale de $xavT_1$ 35
1.9       Claustrum       25         2.1       Planche axiale de $xavT_1$ 34         2.2       Planche coronale de $xavT_1$ 35
2.1Planche axiale de $xavT_1$ 342.2Planche coronale de $xavT_1$ 353.1Flanche coronale de $xavT_1$ 35
2.2 Planche coronale de $xavT_1$
2.3 Planche sagittale de $xavT_1$ 36
2.4 Eclaté du système nerveux central
2.5 Coupe sagittale n°90 de $xavT_1$
2.6 Acquisitions multiples
2.7 Saturation de la dynamique à 8 bits
2.8 Réduction de la dynamique à 8 bits
2.9 Observation du bruit
2.10 Filtrages classiques contre le bruit
2.11 Radiométrie de la substance blanche le long des coupes axiales
2.12 Visualisation de volumes partiels dus à l'effet de mélange
2.13 Observation du décalage chimique
2.14 Zoom d'une partie de coupe axiale en IRM 3D
4.1 Histogramme 2D de l'image bi-acquisitions $(xavT_1; xavT_{2a})$
4.2 Histogramme 1D des ensembles d'apprentissage de $xavT_1$
4.3 Classifications bayésiennes en 1D
4.4 Mauvaises classifications bayésiennes en 1D
4.5 Régions de l'espace 2D de décision bayésienne
4.6 Classifications bayésiennes bi-dimensionnelles
4.7 Classification bayésienne bi-dimensionnelle avec rejet
5.1 Classification par $k$ -movennes
5.2 Espaces de décision en fonction de $d$
5.3 Localisation des $k$ -movennes
5.4 Histogrammes des écarts aux $k$ -movennes optimales $\ldots \ldots 33$
5.5 Résultat non flou de classification floue

5.6	Comportement extrême des c-moyennes floues	98
5.7	Comportement « normal » des c-moyennes floues	99
5.8	Classes floues par l'algorithme des c-moyennes floues	100
5.9	Définition d'une fonction d'appartenance trapézoïdale	104
5.10	Fonctions d'appartenance floue apprises de l'histogramme	105
5.11	Classes floues données par apprentissage des fonctions d'appartenance floue à partir	
	de l'histogramme	108
5.12	Classification par apprentissage des fonctions d'appartenance floue à partir de l'his-	
	togramme	109
<b>C</b> 1	Secondarian de non Transferrien non contentuelle	121
6.1	Segmentation de $xavT_1$ par classification non-contextuelle	131
0.2 6.2	Segmentation de $xavT_1$ par intrage majoritaire d'une classification non-contextuelle Segmentation contextuelle de rege $T$ , par classification locale sur le moveme	132
0.3	Segmentation contextuelle de $xavT_1$ par classification locale sur la móyenne	133
0.4	Segmentation contextuelle de $xav I_1$ par classification locale sur le median $\dots$	134
6.5	Segmentation de $xavI_1$ par classification markovienne avec recuit simule	135
6.6	Segmentation de $xavT_1$ par classification markovienne par ICM	136
6.7	Planche de l'image de la fonction de potentiel $\phi_{CTX}$ de localisation spatiale	137
6.8	Planche de l'image de la fonction de potentiel $\phi_{NCE}$ de localisation spatiale	138
6.9	Comparaison de deux segmentations contextuelles en 5 classes, locale et globale	140
6.10	Segmentation de $xavT_1$ par classification markovienne par ICM, avec des potentiels	
	de localisation	141
6.11	Surfaces de partage des eaux	144
6.12	Segmentation de $xavT_1$ par classification markovienne sur graphe d'adjacence de	
	régions	146
6.13	Segmentation de $xavT_1$ par classification markovienne sur graphe d'adjacence de	
	régions (6-fermeture)	147
6.14	Segmentation de $xavT_1$ par classification markovienne sur graphe d'adjacence de	
	régions (18-fermeture)	148
6.15	Différents types d'éléments de surface de partage des eaux	149
6.16	Cas d'un point surfacique connexe à plus de 2 bassins	150
6.17	Nouvelle définition d'un graphe à partir de la surface de partage des eaux	151
71	Segmentation mombelogique du convegu	150
7.1	Segmentation morphologique simple des sillons	161
7.2 7.2	Segmentation morphologique du sustème ventriculaire	162
7.5 7.4	Segmentation morphologique de l'envelopme cérébrale et des sillons	105
7.4 7.5	Segmentation morphologique de l'enveloppe celebrale et des smons	100
7.5	Segmentation morphologique du conex.	100
7.0 7.7	Segmentation morphologique des noyaux centraux	170
7.1	Planche de coupes axiales de la companyation $xavi_1$	1/1
1.8	Planche de coupes axiales de la segmentation morphologique de $xavI_1$	1/2
8.1	Procédure d'évaluation de l'effet de volume partiel	178
8.2	Régions d'étude de l'effet de volume partiel	181
8.3	Régions d'étude de l'effet de volume partiel (suite)	182
8.4	Evolution de la movenne radiométrique dans les interfaces entre matières	183
8.5	Modification de l'évolution des radiométries en cas de régularisation initiale	186
8.6	Coupe épaisse extraite de deux acquisitions de modalités différentes	187
8.7	Définition des interfaces dans lesquelles intervient la pathologie	188

8.8 Image du pourcentage de pathologie	189
9.1 Navigateur dans les coupes d'IRM	201
9.2 Plateforme de segmentation tridimensionnelle	202
9.3 Coupe axiale d'un atlas numérique de Talairach	204
9.4 Sommaire du Digital Anatomist Project	206
9.5 Panneau extrait du <i>Whole Brain Atlas</i>	207
9.6 Pages extraites du <i>BrainWeb</i>	207
9.7 Atlas de Talairach de <i>CIeMed</i>	208
9.8 The SPL Anatomy Browser	209
11.1 Coupe axiale de l'image-modèle et de l'atlas	227
11.2 Structure de données des objets segmentés	234
11.3 Recalage surfacique	235
11.4 Convergence du champ après une initialisation passable	247
11.5 Convergence du champ après une initialisation correcte	248
12.1 Transformation inverse d'un objet binaire par le champ de correspondance .	252
12.2 Elément structurant flou pour une information directionnelle par dilatation .	257
12.3 Information directionnelle	258
12.4 Informations floues de distances spatiales relatives	260
12.5 Région d'intérêt floue	262
12.6 Classification par $k$ -moyennes dans une region d'interet floue	265
12.7 Regions à selectionner issues de classifications	271
	2/1
13.1 Initialisation du champ de correspondance avec l'objet cerveau (coupe axiale)	278
13.2 Etape 1 : reconnaissance du ventricule latéral droit	280
13.3 Modification du champ de correspondance après l'étape 1	282
13.4 Etape 2 : reconnaissance du ventricule latéral gauche	283
13.5 Modification du champ de correspondance après l'étape 2	285
13.6 Etape 3 : reconnaissance du noyau caudé droit	286
13.7 Modification du champ de correspondance après l'étape 3	288
12.9 Etano 4, magannaissanas du nutaman duoit	200
13.8 Etape 4: reconnaissance du putamen droit	289
13.8 Etape 4 : leconnaissance du putamen droit :	
13.8 Etape 4 : reconnaissance du putatien droit	
13.8 Etape 4 : reconnaissance du putatien droit	
<ul> <li>13.8 Etape 4 : reconnaissance du putatien droit</li></ul>	
<ul> <li>13.8 Etape 4 : reconnaissance du putatien droit</li></ul>	
<ul> <li>13.8 Etape 4 : reconnaissance du putatien droit</li></ul>	
<ul> <li>13.8 Etape 4 : reconnaissance du putatien droit</li></ul>	
13.8 Etape 4 : reconnaissance du putatien droit       1         13.9 Modification du champ de correspondance après l'étape 4	
13.8 Etape 4 : reconnaissance du putatien droit       1         13.9 Modification du champ de correspondance après l'étape 4	
13.8 Etape 4 : reconnaissance du putatien droit       1         13.9 Modification du champ de correspondance après l'étape 4	
13.8 Etape 4 : reconnaissance du putatien droit       1         13.9 Modification du champ de correspondance après l'étape 4	
13.8 Etape 4 : reconnaissance du putatien droit       1         13.9 Modification du champ de correspondance après l'étape 4	
13.8 Etape 4 : reconnaissance du putatien droit       1         13.9 Modification du champ de correspondance après l'étape 4       1         13.10Etape 5 : reconnaissance du quatrième ventricule       1         13.11Etape 6 : reconnaissance du troisième ventricule (vue sagittale)       1         13.12Modification du champ de correspondance après l'étape 6 (vue sagittale)       1         13.13Reconnaissance – planche A, vue axiale 1/2       1         13.14Reconnaissance – planche A, vue axiale 2/2       1         13.15Reconnaissance – planche B, vue axiale 1/2       1         13.16Reconnaissance – planche B, vue axiale 2/2       1         13.17Reconnaissance – planche A, vue coronale 1/2       1         13.18Reconnaissance – planche A, vue coronale 1/2       1         13.19Reconnaissance – planche A, vue coronale 1/2       1         13.19Reconnaissance – planche A, vue coronale 1/2       1         13.19Reconnaissance – planche A, vue coronale 2/2       1         13.19Reconnaissance – planche B, vue coronale 2/2       1         13.19Reconnaissance – planche A, vue coronale 1/2       1         13.20Reconnaissance – planche A, vue sagittale 1/2       1         13.21Reconnaissance – planche A, vue sagittale 1/2       1         13.21Reconnaissance – planche A, vue sagittale 1/2       1	

13.23	BReconnaissance – planche B, vue sagittale 1/2	306
13.24	4Reconnaissance – planche B, vue sagittale 2/2	307
13.25	5Reconnaissance – vue 3D du système ventriculaire	308
13.26	6Reconnaissance – vue 3D des ventricules latéraux et des noyaux	309
13.27	7Champ de déformation après les 7 étapes	311
B.1	Centième étape d'un recuit biaisé.	338
$C_{1}$	Résultat de la segmentation morphologique du cerveau sur l'image <i>cu sag</i> superpo-	
0.1	sée à quelques coupes du volume original	343
C 2	Résultat de la segmentation morphologique du cerveau sur l'image <i>enil1</i> superposée	010
0.2	à quelques coupes du volume original	344
C.3	Résultat de la segmentation morphologique du cerveau sur l'image <i>la sag</i> , superpo-	511
0.0	sée à quelques coupes du volume original.	345
C.4	Résultat de la segmentation morphologique du cerveau sur l'image <i>nass</i> , superposée	0.0
0	à quelques coupes du volume original.	346
C.5	Résultat de la segmentation morphologique du cerveau sur l'image <i>post</i> , superposée	
	à quelques coupes du volume original.	347
C.6	Résultat de la segmentation morphologique du cerveau sur l'image sa sag. superpo-	
	sée à quelques coupes du volume original.	348
C.7	Résultat de la segmentation morphologique du cerveau sur l'image <i>sov2</i> , superposée	
	à quelques coupes du volume original.	349
C.8	Résultat de la segmentation morphologique du cerveau sur l'image <i>ton2</i> , superposée	
	à quelques coupes du volume original.	350
C.9	Résultat de la segmentation morphologique du cerveau sur l'image <i>totex2</i> , superpo-	
	sée à quelques coupes du volume original.	351
C.10	Estimation des fonctions d'appartenance au liquide céphalo-rachidien, substance grise	
	et substance blanche sur <i>nass</i> . <i>sov2</i> . <i>ton2</i> et <i>totex2</i>	353
C.11	Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons	
	et des ventricules sur l'image <i>epil1</i> , superposée à quelques coupes du volume original.	355
C.12	Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons	
	et des ventricules sur l'image <i>nass</i> , superposée à quelques coupes du volume original.	356
C.13	Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons	
	et des ventricules sur l'image <i>post</i> , superposée à quelques coupes du volume original.	357
C.14	Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons	
	et des ventricules sur l'image <i>soy2</i> , superposée à quelques coupes du volume original.	358
C.15	Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons	
	et des ventricules sur l'image <i>ton2</i> , superposée à quelques coupes du volume original.	359
C.16	Résultat de la segmentation morphologique du liquide céphalo-rachidien des sillons	
	et des ventricules sur l'image totex2, superposée à quelques coupes du volume original.	360
C.17	Résultat de la segmentation morphologique des noyaux centraux sur l'image epil1,	
	superposée à quelques coupes du volume original.	362
C.18	Résultat de la segmentation morphologique des noyaux centraux sur l'image nass,	
	superposée à quelques coupes du volume original.	363
C.19	Résultat de la segmentation morphologique des noyaux centraux sur l'image post,	
	superposée à quelques coupes du volume original.	364
C.20	Résultat de la segmentation morphologique des noyaux centraux sur l'image soy2,	
	superposée à quelques coupes du volume original.	365

C.21	Résultat de la segmentation morphologique des noyaux centraux sur l'image ton2,	
	superposée à quelques coupes du volume original	366
C.22	Résultat de la segmentation morphologique des noyaux centraux sur l'image <i>totex2</i> ,	
	superposée à quelques coupes du volume original	367
C.23	Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image epil1,	
	superposée à quelques coupes du volume original	369
C.24	Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image nass,	
	superposée à quelques coupes du volume original.	370
C.25	Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image post,	
	superposée à quelques coupes du volume original.	371
C.26	Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image soy2,	
	superposée à quelques coupes du volume original.	372
C.27	Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image <i>ton2</i> ,	
	superposée à quelques coupes du volume original.	373
C.28	Résultat de la segmentation morphologique de l'interface gris/blanc sur l'image to-	
	<i>tex2</i> , superposée à quelques coupes du volume original.	374
C.29	Une vue en perspective de la segmentation obtenue sur <i>epil1</i>	375
C.30	Résultat de la segmentation globale sur l'image <i>epil1</i> , superposée à quelques coupes	
	du volume original.	376
C.31	Résultat de la segmentation globale sur l'image <i>nass</i> , superposée à quelques coupes	
	du volume original.	377
C.32	Résultat de la segmentation globale sur l'image <i>post</i> , superposée à quelques coupes	
	du volume original.	378
C.33	Résultat de la segmentation globale sur l'image <i>sov2</i> , superposée à quelques coupes	
	du volume original.	379
C.34	Résultat de la segmentation globale sur l'image <i>ton2</i> , superposée à quelques coupes	
	du volume original.	380
C.35	Résultat de la segmentation globale sur l'image <i>totex2</i> , superposée à quelques coupes	
	du volume original.	381
D.1	Lena traitée par TIVOLI	385

416 Table des figures

## Liste des tableaux

1.1 1.2 1.3 1.4 1.5	Objets de type "aire"	26 27 28 29 29
2.1 2.2 2.3 2.4	Taille de confiance d'un ensemble d'apprentissage $(P = 0.95)$	50 50 51
2.5	Statistiques radiométriques pures obtenues par apprentissage	52
4.1	Notations pour la classification	66
5.1 5.2	$k$ -moyennes obtenues empiriquement pour l'image bi-modalité ( $xavT_1$ ; $xavT_{2a}$ ) Écart moyen entre les $k$ -moyennes issues de descentes successives et les $k$ -moyennes	90
5.3 5.4	optimales pour l'image bi-modalité $(xavT_1; xavT_{2a})$ Statistiques calculées sur les classes floues	94 107 107
6.1 6.2	Matrice de Potts pour la segmentation du cerveau en 4 classes	129 139
8.1 8.2 8.3 8.4	Algorithme de calcul d'une carte de la plus proche région	179 184 185 186
11.1 11.2 11.3 11.4 11.5	Notations pour l'expression de la structure d'une image       2         Notations pour l'expression de champs discrets de déformation       2         Propriétés résultant des notations       2         Algorithme de calcul d'une carte de plus proche voisin       2         Algorithme de regularisation surfacique       2	228 229 229 237 238
11.6 11.7	Remplacement d'une valeur de correspondance    2      Liste d'opérateurs algorithmiques    2	242 242
11.8	Algorithme de résolution de $\triangle .F_R = \vec{0}$	243
11.9	DAlgorithme n°2 d'extension du champ de correspondance $\dots \dots \dots$	244

11.1	1Nombre d'itérations nécessaires à la convergence
12.1	Informations disponibles pour la fusion
C.1	Caractéristiques des images de référence
C.2	Résultats de la segmentation du cerveau
C.3	Moyenne et écart-type de chaque classe obtenus par apprentissage automatique. Deux
	valeurs sont données pour chaque paramètre, correspondant aux valeurs obtenues en
	considérant tous les points pour le calcul ou seulement ceux d'appartenance supé-
	rieure à 0,5 respectivement
C.4	Résultats de la segmentation du liquide céphalo-rachidien des sillons et des ventricules354
C.5	Résultats de la segmentation des noyaux centraux