



**HAL**  
open science

# Fusion d'informations et segmentation d'images basées sur la théorie des fonctions de croyance : Application à l'imagerie médicale TEP multi-traceurs

Benoît Lelandais

## ► To cite this version:

Benoît Lelandais. Fusion d'informations et segmentation d'images basées sur la théorie des fonctions de croyance : Application à l'imagerie médicale TEP multi-traceurs. Traitement des images [eess.IV]. Université de Rouen, 2013. Français. NNT: . tel-00912534

**HAL Id: tel-00912534**

**<https://theses.hal.science/tel-00912534>**

Submitted on 3 Dec 2013

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

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

UNIVERSITÉ DE ROUEN

LABORATOIRE D'INFORMATIQUE, DU TRAITEMENT DE L'INFORMATION ET DES SYSTÈMES  
École doctorale : SCIENCES PHYSIQUES, MATHÉMATIQUES ET DE L'INFORMATION POUR L'INGÉNIEUR

Discipline : PHYSIQUE - TRAITEMENT DU SIGNAL

# THÈSE

présentée par :

BENOÎT LELANDAIS

pour l'obtention du Grade de :

DOCTEUR DE L'UNIVERSITÉ DE ROUEN

---

## Fusion d'informations et segmentation d'images basées sur la théorie des fonctions de croyance : Application à l'imagerie médicale TEP multi-traceurs

---

Directeurs de Thèse :

Mme ISABELLE GARDIN

M. LAURENT MOUCHARD

Soutenue le 23 avril 2013 devant le jury composé de :

Pr WOJCIECH PIECZYNSKI	TELECOM SudParis	Président du jury
Pr VINCENT BARRA	Université Blaise Pascal de Clermont-Ferrand	Rapporteur
Pr THIERRY DENŒUX	Université de Technologie de Compiègne	Rapporteur
Pr SU RUAN	Université de Rouen	Examineur
Mme ISABELLE GARDIN	Centre Henri-Becquerel de Rouen	Directeur
M. LAURENT MOUCHARD	Université de Rouen	Directeur



# Remerciements

Je tiens à remercier en premier lieu les membres du jury de cette thèse pour l'intérêt porté à mes travaux. Je remercie tout particulièrement Monsieur Vincent BARRA, Professeur à l'Université Blaise Pascal de Clermont-Ferrand, et Monsieur Thierry DENŒUX, Professeur à l'Université de Technologie de Compiègne, d'avoir accepté de rapporter ma thèse. Je remercie également Monsieur Wojciech PIECZYNSKI, Professeur à TELECOM SudParis, de m'avoir fait l'honneur de présider le jury. Je suis particulièrement reconnaissant pour l'ensemble des remarques formulées, critiques et conseils très enrichissants qui m'ont été prodigués.

Je souhaite exprimer ma reconnaissance à Madame Isabelle GARDIN, HDR au Centre Henri Becquerel de Rouen, ainsi qu'à Monsieur Laurent MOUCHARD, MdC à l'Université de Rouen, qui ont encadré cette thèse. Je les remercie pour leur conseils très instructifs dans le domaine scientifique, et pour leur disponibilité notable, propices au bon déroulement de ma thèse. Je tiens également à les remercier pour leur aide précieuse m'ayant permis de parfaire la réalisation de ce mémoire. Ma reconnaissance va également à Madame Su RUAN, Professeur à l'Université de Rouen, pour son expertise et ses conseils pertinents.

Ma gratitude va ensuite à Monsieur Pierre VERA, Professeur au Centre Henri Becquerel de Rouen, qui m'a accepté dans son équipe, ainsi qu'à Monsieur Bernard DUBRAY, Professeur au Centre Henri Becquerel de Rouen et à Monsieur Sébastien THUREAU, pour leur expertise dans le domaine médical et leurs remarques instructives. Ma gratitude va également à Monsieur Sébastien HAPDEY, qui m'a été d'une aide précieuse pour l'acquisition des images de fantômes.

Je remercie tous les membres de l'équipe QuantIF, qui ont rendu ces années de thèse agréables et sympathiques.

Merci à ma famille, à mes amis et à ma compagne, pour leur soutien constant et leurs encouragements réguliers.



# Résumé

L'imagerie fonctionnelle par Tomographie d'Émission de Positons (TEP) multi-traceurs pourrait avoir un rôle essentiel dans le traitement du cancer par radiothérapie externe. Les images TEP aux traceurs  $^{18}\text{F}$ Fluoro-Déoxy-Glucose ( $^{18}\text{F}$ FDG),  $^{18}\text{F}$ -Fluoro-L Thymidine ( $^{18}\text{F}$ FLT) et  $^{18}\text{F}$ Fluoro-Misonidazole ( $^{18}\text{F}$ Miso) sont respectivement témoins du métabolisme glucidique, de la prolifération cellulaire et de l'hypoxie (manque d'oxygénation des cellules). L'utilisation conjointe de ces trois traceurs pourrait permettre de définir des sous-volumes donnant lieu à un traitement particulier. À cet effet, il est impératif de mettre à la disposition du corps médical un outil de segmentation et de fusion de ces images.

Les images TEP ont pour caractéristique d'être très bruitées et d'avoir une faible résolution spatiale. Ces imperfections ont pour conséquence respective d'induire la présence d'informations incertaines et imprécises dans les images. Notre contribution réside dans la proposition d'une méthode, nommée EVEII pour *Evidential Voxel-based Estimation of Imperfect Information*, basée sur la théorie des fonctions de croyance, offrant une segmentation fiable et précise dans le contexte d'images imparfaites. Elle réside également dans la proposition d'une méthode de fusion d'images TEP multi-traceur.

L'étude d'EVEII sur des images simulées a révélé qu'elle est la mieux adaptée comparée à d'autres méthodes basées sur la théorie des fonctions de croyance, en donnant un taux de bonne reconnaissance des pixels de près de 100 % lorsque le rapport signal-sur-bruit dépasse 2,5.

Sur les fantômes TEP physiques, simulant les caractéristiques des images TEP au  $^{18}\text{F}$ FDG, à la  $^{18}\text{F}$ FLT et au  $^{18}\text{F}$ Miso, les résultats ont montré que notre méthode estime le mieux les volumes des sphères à segmenter comparé à des méthodes de la littérature proposées à cet effet. Sur les deux fantômes faiblement et fortement bruités respectivement, les biais moyens d'erreur d'estimation des volumes sont seulement de -0,27 et 3,89 mL, témoignant de sa pertinence à visée de segmentation d'images TEP.

Enfin, notre méthode a été appliquée à la segmentation d'images TEP multi-traceurs chez trois patients. Les résultats ont montré que notre méthode est adaptée à la fusion d'images TEP multi-traceurs, offrant à cet effet un ensemble d'images paramétriques permettant de différencier les différents tissus biologiques.

**Mots clés :** Incertitude, Imprécision, Fusion d'informations, Fonctions de croyance, Traitement d'images, Segmentation, TEP, Dose painting, FDG, FLT, FMISO.



# Abstract

Multi-tracer Positron Emission Tomography (PET) functional imaging could have a prominent effect for the treatment of cancer by radiotherapy. PET images using  $^{18}\text{F}$ -Fluoro-Deoxy-Glucose ( $^{18}\text{FDG}$ ),  $^{18}\text{F}$ -Fluoro-L Thymidine ( $^{18}\text{FLT}$ ) and  $^{18}\text{F}$ -Fluoro-Misonidazole ( $^{18}\text{FMiso}$ ) tracers are respectively indicators of glucose cell consumption, cell proliferation and hypoxia (cell lack of oxygen). The joint use of these three tracers could help us to define sub-volumes leading to an adequate treatment. For this purpose, it is imperative to provide a medical tool of segmentation and fusion of these images.

PET images have the characteristic of being very noisy and having a low spatial resolution. These imperfections result in the presence of uncertain and imprecise information in the images respectively. Our contribution consists in proposing a method, called EVEII for *Evidential Voxel-based Estimation of Imperfect Information*, based on belief function theory, for providing a reliable and accurate segmentation in the context of imperfect images. It also lies in proposing a method for the fusion of multi-tracer PET images.

The study of EVEII on simulated images reveals that it is the best suited compared to other methods based on belief function theory, giving a good recognition rate of almost 100 % of pixels when the signal-to-noise ratio is greater than 2.5.

On PET physical phantoms, simulating the characteristics of  $^{18}\text{FDG}$ ,  $^{18}\text{FLT}$  and  $^{18}\text{FMiso}$  PET images, the results show that our method gives the better estimation of sphere volumes to segment compared to methods of the literature proposed for this purpose. On both lowly and highly noisy phantoms respectively, mean error bias of volume estimation are only of -0.27 and 3.89 mL, demonstrating its suitability for PET image segmentation task.

Finally, our method is applied to the segmentation of multi-tracer PET images for three patients. The results show that our method is well suited for the fusion of multi-tracer PET images, giving for this purpose a set of parametric images for differentiating the different biological tissues.

**Keywords :** Uncertainty, Imprecision, Information fusion, Belief Function, Image processing, Segmentation, Dose painting, PET, FDG, FLT, FMISO.





# Table des matières

<b>Introduction</b>	<b>17</b>
<b>1 Place de l'imagerie TEP dans le traitement par radiothérapie</b>	<b>21</b>
1.1 Principe de l'imagerie TEP/TDM . . . . .	21
1.1.1 Imagerie médicale multimodale . . . . .	21
1.1.1.1 Généralités . . . . .	21
1.1.2 Principe de l'imagerie anatomique TDM . . . . .	25
1.1.2.1 Générateur de rayons X . . . . .	25
1.1.2.2 Système de détection . . . . .	26
1.1.3 Principe de l'imagerie fonctionnelle TEP . . . . .	27
1.1.3.1 Noyau radioactif . . . . .	27
1.1.3.2 Radiopharmaceutiques . . . . .	28
1.1.3.3 Système de détection . . . . .	29
1.1.4 Reconstruction Tomographique . . . . .	31
1.1.4.1 Méthode FBP . . . . .	32
1.1.4.2 Méthode OSEM . . . . .	33
1.1.5 Caractéristiques des images TEP/TDM reconstruites . . . . .	35
1.1.5.1 Les images TDM . . . . .	35
1.1.5.2 Les images TEP . . . . .	37
1.1.5.3 Les images TEP/TDM . . . . .	40
1.1.6 Conclusion . . . . .	41
1.2 Place de l'imagerie TEP en radiothérapie . . . . .	41
1.2.1 Principe de la radiothérapie externe . . . . .	41
1.2.1.1 Introduction . . . . .	41
1.2.1.2 Acquisition des données . . . . .	42
1.2.1.3 Définition des volumes cible . . . . .	42
1.2.2 Apport de l'imagerie TEP en radiothérapie . . . . .	43

1.2.2.1	Introduction . . . . .	43
1.2.2.2	Diagnostic . . . . .	43
1.2.2.3	Définition des volumes cible . . . . .	44
1.2.2.4	Suivi thérapeutique . . . . .	45
1.3	Conclusion . . . . .	45
<b>2</b>	<b>Segmentation d'images TEP</b>	<b>47</b>
2.1	Introduction . . . . .	47
2.2	État de l'art des méthodes de segmentation des lésions . . . . .	48
2.2.1	Approches par seuillage . . . . .	49
2.2.1.1	Principe . . . . .	49
2.2.1.2	État de l'art . . . . .	49
2.2.2	Approches par croissance de régions . . . . .	52
2.2.2.1	Principe . . . . .	52
2.2.2.2	État de l'art . . . . .	53
2.2.3	Approches dérivatives . . . . .	53
2.2.3.1	Principe . . . . .	53
2.2.3.2	État de l'art . . . . .	54
2.2.4	Modèle déformable . . . . .	55
2.2.5	Approches probabilistes . . . . .	56
2.2.5.1	Principe . . . . .	56
2.2.5.2	État de l'art . . . . .	56
2.2.6	Approche floue . . . . .	59
2.2.6.1	Principe . . . . .	59
2.2.6.2	État de l'art . . . . .	60
2.2.7	Approche par fusion . . . . .	61
2.2.8	Méthodes basées sur la texture . . . . .	61
2.2.8.1	Principe . . . . .	61
2.2.8.2	État de l'art . . . . .	62
2.3	Évaluation de sept méthodes de segmentation . . . . .	63
2.3.1	Matériels et méthodes . . . . .	63
2.3.1.1	Acquisition des données . . . . .	63

---

2.3.1.2	Méthodes de segmentation évaluées . . . . .	64
2.3.1.3	Implémentation des méthodes . . . . .	65
2.3.2	Analyse des données . . . . .	66
2.3.3	Résultats . . . . .	66
2.3.3.1	Seuillage fixe à 40% du maximum . . . . .	66
2.3.3.2	Seuillage adaptatif . . . . .	67
2.3.3.3	Expectation-Maximization . . . . .	67
2.3.3.4	Fuzzy C-means . . . . .	69
2.3.3.5	Gaussian Mixture Model . . . . .	69
2.3.3.6	Fuzzy C-means-Spatial Wavelet . . . . .	69
2.3.3.7	Fuzzy Local Adaptatif Bayésien . . . . .	70
2.3.3.8	Discussion . . . . .	70
2.4	Conclusion . . . . .	71
<b>3</b>	<b>État de l'art de la fusion d'information en imagerie médicale</b>	<b>73</b>
3.1	Introduction . . . . .	73
3.2	Imperfections en imagerie . . . . .	76
3.2.1	Imperfections d'une source d'information . . . . .	77
3.2.2	Liens entre plusieurs sources d'information . . . . .	79
3.3	État de l'art des méthodes de fusion en imagerie médicale . . . . .	81
3.3.1	Fusion par le vote . . . . .	81
3.3.1.1	Principe . . . . .	81
3.3.1.2	État de l'art . . . . .	82
3.3.2	Fusion par approche probabiliste . . . . .	82
3.3.2.1	Principe . . . . .	82
3.3.2.2	État de l'art . . . . .	83
3.3.3	Fusion par approche possibiliste . . . . .	83
3.3.3.1	Principe . . . . .	83
3.3.3.2	État de l'art . . . . .	85
3.3.4	Fusion par fonctions de croyance . . . . .	87
3.3.4.1	Principe . . . . .	87
3.3.4.2	État de l'art . . . . .	88

3.4	Conclusion . . . . .	90
<b>4</b>	<b>Théorie des fonctions de croyance</b>	<b>93</b>
4.1	Introduction . . . . .	93
4.2	Bases théoriques . . . . .	95
4.2.1	Définition du cadre de discernement . . . . .	95
4.2.2	Fonction de masse de croyance . . . . .	95
4.2.3	Transformations de la fonction de masse . . . . .	96
4.3	Révision des croyances . . . . .	97
4.3.1	Combinaison conjonctive . . . . .	98
4.3.2	Combinaison orthogonale de Dempster . . . . .	98
4.3.3	Conditionnement . . . . .	99
4.3.4	Combinaison disjonctive . . . . .	100
4.3.5	Autres opérateurs de combinaison . . . . .	100
4.3.6	Affaiblissement . . . . .	101
4.4	Modélisation des croyances . . . . .	102
4.4.1	Modèles basés sur une approche probabiliste . . . . .	102
4.4.2	Approches basées sur des informations de distance . . . . .	103
4.4.2.1	Modèle basé sur les k-plus proches voisins . . . . .	103
4.4.2.2	C-moyennes évidentiel . . . . .	105
4.4.3	Approches en imagerie . . . . .	106
4.4.3.1	Approche par histogramme . . . . .	106
4.4.3.2	Approche par morphologie mathématique . . . . .	107
4.5	Décision . . . . .	109
4.6	Applications en imagerie . . . . .	110
4.7	Conclusion . . . . .	114
<b>5</b>	<b>Segmentation d'images TEP mono et multi-traceurs</b>	<b>117</b>
5.1	Introduction . . . . .	117
5.2	Segmentation mono-traceur . . . . .	120
5.2.1	EVEII . . . . .	120
5.2.1.1	Définition du cadre de discernement . . . . .	121

5.2.1.2	Définition des sources d'information . . . . .	121
5.2.1.3	Définition du voisinage et du coefficient de pondération $\alpha$ . . .	121
5.2.1.4	Estimation des masses de croyance . . . . .	122
5.2.1.5	Combinaison disjonctive des informations de voisinage pondérées	124
5.2.1.6	Combinaison conjonctive des informations de voisinage pondérées	125
5.2.2	EVEII <sub>3</sub> . . . . .	126
5.2.3	Réduction des imprécisions . . . . .	127
5.2.3.1	Intégration d'une connaissance <i>a priori</i> . . . . .	127
5.2.3.2	Calcul de la connaissance <i>a priori</i> . . . . .	128
5.2.4	Prise de décision . . . . .	128
5.3	Segmentation multi-traceurs . . . . .	129
5.3.1	Cadre de discernement . . . . .	129
5.3.2	Estimation des masses de croyance . . . . .	130
5.3.3	Fusion des images TEP multi-traceurs . . . . .	131
5.3.4	Prise de décision . . . . .	132
5.4	Conclusion . . . . .	133
<b>6</b>	<b>Évaluation et expérimentation</b>	<b>135</b>
6.1	Introduction . . . . .	135
6.2	Évaluation d'EVEII sur des images simulées . . . . .	136
6.2.1	Matériel et méthodes . . . . .	136
6.2.1.1	Images simulées . . . . .	136
6.2.1.2	Méthodes évaluées . . . . .	138
6.2.1.3	Évaluation . . . . .	138
6.2.2	Résultats . . . . .	141
6.2.3	Discussion . . . . .	146
6.2.4	Conclusion . . . . .	148
6.3	Évaluation d'EVEII sur des images de fantôme TEP . . . . .	149
6.3.1	Paramétrage de la méthode . . . . .	149
6.3.1.1	Apprentissage de la connaissance <i>a priori</i> . . . . .	149
6.3.2	Fantôme 1 . . . . .	152
6.3.2.1	Matériels et méthodes . . . . .	152

6.3.2.2	Résultats . . . . .	154
6.3.2.3	Discussion . . . . .	157
6.3.3	Fantôme 2 . . . . .	158
6.3.3.1	Matériels et méthodes . . . . .	158
6.3.3.2	Résultats . . . . .	162
6.3.3.3	Discussion . . . . .	164
6.3.4	Conclusion . . . . .	166
6.4	Application de la méthode aux images TEP multi-traceurs . . . . .	167
6.4.1	Matériel et méthodes . . . . .	167
6.4.1.1	Données patients . . . . .	167
6.4.1.2	Segmentation mono-traceur . . . . .	168
6.4.1.3	Segmentation multi-traceurs . . . . .	169
6.4.1.4	Analyse des données . . . . .	169
6.4.2	Résultats . . . . .	170
6.4.2.1	Segmentation mono-traceur . . . . .	170
6.4.2.2	Segmentation multi-traceurs . . . . .	173
6.4.3	Discussion . . . . .	174
6.5	Conclusion . . . . .	175
	<b>Conclusion et perspectives</b>	<b>177</b>
	<b>Liste des publications Personnelles</b>	<b>181</b>
	<b>Bibliographie</b>	<b>183</b>
<b>A</b>	<b>Théorie des fonctions de croyance au travers d'exemples</b>	<b>205</b>
A.1	Bases théoriques . . . . .	205
A.1.1	Principe des fonctions de croyance à partir d'un exemple . . . . .	205
A.1.2	Définition du cadre de discernement . . . . .	207
A.1.3	Transformations de la fonction de masse . . . . .	207
A.2	Révision des croyances . . . . .	209
A.2.1	Combinaison conjonctive . . . . .	209
A.2.2	Combinaison orthogonale de Dempster . . . . .	210

A.2.3	Conditionnement . . . . .	210
A.2.4	Combinaison disjonctive . . . . .	211
A.2.5	Autres opérateurs de combinaison . . . . .	212





# Introduction

L'imagerie médicale permet de représenter le corps humain à des fins de diagnostic ou de thérapie. On distingue deux types d'imagerie, l'imagerie anatomique et l'imagerie fonctionnelle. Dans le cadre du traitement du cancer par radiothérapie externe, l'imagerie anatomique par TomoDensitoMétrie (TDM), utilisée pour la délimitation du volume cible à irradier (*Gross Tumor Volume* : GTV), est l'outil de prédilection pour la planification du traitement. Depuis une dizaine d'année, l'imagerie fonctionnelle par Tomographie d'Émission de Positons (TEP) au radiotracteur  $^{18}\text{Fluoro-Déoxy-Glucose}$  ( $^{18}\text{FDG}$ ) est utilisée conjointement à l'imagerie TDM. Elle est témoin du métabolisme glucidique des cellules, qui, du fait de son accroissement dans les tissus tumoraux par rapport aux tissus sains, offre une meilleure localisation tumorale qu'en utilisant la TDM seule [Fox *et al.*, 2005]. La notion de *Biological Target Volume* (BTV) [Ling *et al.*, 2000] a été proposée dans le but de définir plusieurs sous-volumes du GTV en tirant partie de l'imagerie fonctionnelle. Cette information permet de moduler la délivrance de la dose d'irradiation dans le GTV, en identifiant les zones métaboliquement actives. Cette stratégie thérapeutique est nommée *Dose Painting* [Hall, 2005].

L'émergence de nouveaux radiotraceurs en imagerie TEP devrait jouer un rôle essentiel dans le traitement des tumeurs [Lecchi *et al.*, 2008]. Les radiotraceurs  $^{18}\text{F-Fluoro-L Thymidine}$  ( $^{18}\text{FLT}$ ) et  $^{18}\text{Fluoro-Misonidazole}$  ( $^{18}\text{FMiso}$ ) sont notamment témoins de la prolifération cellulaire et de l'hypoxie<sup>1</sup> respectivement. Leur utilisation pourrait permettre de définir deux sous-volumes tumoraux et donc d'envisager un traitement par radiothérapie avec potentiellement une escalade de dose des sous-volumes hypoxiques et une augmentation de la fréquence des séances d'irradiation des sous-volumes hyper-prolifératifs. Dans ce contexte, l'un des principaux enjeux médicaux porte sur l'amélioration du contrôle loco-régional des tumeurs, avec un traitement par radiothérapie externe incluant la définition de BTV issus d'images TEP multi-traceurs et une stratégie de *Dose Painting*. Pour y parvenir, la mise à disposition d'une méthode de segmentation des BTV fiable et précise, ainsi que d'un outil de fusion de ces BTV sont nécessaires.

La segmentation est une tâche visant à décomposer une image en différentes régions distinctes. En imagerie TEP, la région que l'on cherche à segmenter est celle présentant une forte fixation du traceur. La méthode la plus naïve et la plus communément employée en routine

---

1. Manque d'oxygénation des cellules entraînant leur radiorésistance.

clinique repose sur la délinéation manuelle des hyper-fixations. Cette méthode n'offre pas un résultat reproductible, et n'est, de ce fait, ni fiable ni précise. Il y a ainsi un intérêt majeur à développer des méthodes automatiques. De nombreuses méthodes ont été proposées dans la littérature pour répondre aux problèmes de segmentation de ces images. Du fait de la présence de bruit important et de la faible résolution spatiale des imageurs TEP, la segmentation de ces images est délicate. Par ailleurs, compte tenu des imperfections contenues dans les images, il n'existe pas actuellement de consensus sur la meilleure méthode.

D'un point de vue médical, les images TEP au  $^{18}\text{FDG}$ , à la  $^{18}\text{FLT}$  et au  $^{18}\text{FMiso}$  sont complémentaires. Leur fusion a donc un intérêt majeur. Deux méthodes de fusion ont été proposées dans [David *et al.*, 2009, 2011] pour la fusion d'images TEP. Seulement, les méthodes sont testées sur des images simulées bien contrastées. De plus, dans [David *et al.*, 2011], la méthode est appliquée sur des images TEP au  $^{18}\text{FDG}$  acquises avant et pendant radiothérapie dans le but d'évaluer la réponse au traitement. Cela ne permet pas de prendre en compte le fait que les images issues de traceurs autre que le  $^{18}\text{FDG}$  soient plus faiblement contrastées et présentent un bruit plus important. À notre connaissance, aucune méthode n'a été appliquée à la fusion d'informations à partir d'images TEP multi-traceurs. En outre, les méthodes proposées pour la fusion d'images médicales autres que la TEP sont nombreuses. Parmi elles, on trouve des méthodes qui se basent sur la théorie des possibilités [Zadeh, 1978; Dubois et Prade, 1987] ou des fonctions de croyance [Dempster, 1967; Shafer, 1976]. Ces théories ont l'avantage, dans un premier temps, de permettre de modéliser les incertitudes et les imprécisions respectivement inhérentes au bruit dans les images et à la faible résolution spatiale des images, et d'autre part de fournir des outils de fusion d'informations.

Dans ce contexte, l'objectif de notre travail a été de proposer une méthode de segmentation des hyper-fixations en imagerie TEP au  $^{18}\text{FDG}$ , à la  $^{18}\text{FLT}$  et au  $^{18}\text{FMiso}$ , ainsi qu'une méthode de fusion de ces images. À cet effet, nous nous sommes orientés vers la théorie des fonctions de croyance, aujourd'hui de plus en plus utilisée. Notre manuscrit se décompose en six chapitres.

Dans le premier chapitre, nous présentons la place de l'imagerie TEP dans le traitement par radiothérapie. Nous présentons en particulier comment les images sont acquises et l'origine des imperfections dont elles sont entachées. En outre, nous présentons leur intérêt à visée de radiothérapie externe.

Dans le deuxième chapitre, nous présentons un état de l'art des méthodes de segmentation des hyper-fixations en imagerie TEP. L'étude porte principalement sur le traceur  $^{18}\text{FDG}$ , dont le nombre de méthodes proposées est le plus conséquent dans la littérature, et dans une moindre mesure aux traceurs  $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$ . Afin de conclure sur les performances des méthodes,

sept d'entre elles sont évaluées sur des images TEP au  $^{18}\text{F}$ FDG. Trois de ces méthodes sont retenues pour la suite de nos travaux.

Au troisième chapitre, nous présentons une étude bibliographique des méthodes de fusion en imagerie médicale. Cette étude se focalise principalement sur les méthodes basées sur la théorie des possibilités, mais également sur celles basées sur la théorie des fonctions de croyance.

Le quatrième chapitre est dédié à l'étude de la théorie des fonctions de croyance sur laquelle se base notre méthode. Nous y présentons en particulier les différents concepts de la théorie, ainsi que différentes méthodes de modélisation des croyances que l'on rencontre dans la littérature. Ce chapitre est associé à une annexe illustrant le comportement des opérateurs de la théorie.

Le cinquième chapitre est consacré à la description de notre méthode. Il est scindé en deux parties. La première décrit notre méthode de segmentation des BTV pour chaque image TEP mono-traceur. La seconde décrit notre méthode de segmentation multi-traceur. Nous l'avons appelée EVEII, pour *Evidential Voxel-based Estimation of Imperfect Information*.

Enfin, le sixième chapitre est une évaluation de notre méthode. Trois parties le composent. La première est une évaluation de notre méthode de segmentation sur des images simulées. La deuxième est une évaluation sur des images TEP mono-traceurs. La troisième est une application de notre méthode de segmentation et de fusion sur des images de patients pour illustrer son intérêt à visée de radiothérapie externe.



# Chapitre 1

## Place de l'imagerie TEP dans le traitement par radiothérapie

### Sommaire

---

<b>1.1</b>	<b>Principe de l'imagerie TEP/TDM</b>	<b>21</b>
1.1.1	Imagerie médicale multimodale	21
1.1.2	Principe de l'imagerie anatomique TDM	25
1.1.3	Principe de l'imagerie fonctionnelle TEP	27
1.1.4	Reconstruction Tomographique	31
1.1.5	Caractéristiques des images TEP/TDM reconstruites	35
1.1.6	Conclusion	41
<b>1.2</b>	<b>Place de l'imagerie TEP en radiothérapie</b>	<b>41</b>
1.2.1	Principe de la radiothérapie externe	41
1.2.2	Apport de l'imagerie TEP en radiothérapie	43
<b>1.3</b>	<b>Conclusion</b>	<b>45</b>

---

## 1.1 Principe de l'imagerie TEP/TDM

### 1.1.1 Imagerie médicale multimodale

#### 1.1.1.1 Généralités

##### 1.1.1.1.1 Imagerie numérique 3D

#### Définition

L'image numérique 3D correspond à une matrice en trois dimensions composée de données binaires. À la différence de l'imagerie numérique 2D permettant la représentation d'une surface, l'imagerie 3D permet la représentation d'un volume.

On nomme les points d'une image 2D des pixels (*picture elements*). Lorsque l'image compte trois dimensions, les points sont appelés voxels (*volume elements*). Ce sont des pavés possé-

dant tous une même largeur, une même hauteur et une même profondeur. La visualisation d'une image 3D est réalisée par décomposition en une série d'images 2D, suivant une des trois orientations possibles. Chacune de ces images correspond à une coupe dite, selon l'orientation choisie, transverse, sagittale ou frontale, possédant une épaisseur correspondant respectivement à la profondeur, la largeur ou la hauteur des voxels. Par empilement des coupes successives, le volume est reconstruit.

### Caractéristiques du système de détection et de l'image

Un système de détection, à l'origine de l'obtention d'une image 3D, possède des caractéristiques influençant la qualité de l'information obtenue. Les principales caractéristiques sont la résolution spatiale et le bruit.

La résolution spatiale définit la capacité d'un système de détection à séparer deux structures voisines. On peut la représenter comme la largeur à mi-hauteur (FWHM pour *Full Width at Half Maximum*) de l'image d'un objet d'un millimètre de largeur. La FWHM est une représentation de l'étalement spatial du signal autour du pic d'intensité représentant l'objet (PSF pour *Point Spread Function*). L'image résultante peut alors être vue comme l'objet convolué avec un filtre gaussien de largeur à mi-hauteur la FWHM. Ainsi, une faible résolution spatiale d'un système de détection induit un manque de précision à la frontière des différentes régions de l'image, empêchant la restitution des hautes fréquences.

La Figure 1.1 présente l'influence de la convolution d'une image 2D avec une gaussienne. On peut observer sur l'image convoluée une perte de précision au niveau des contours.

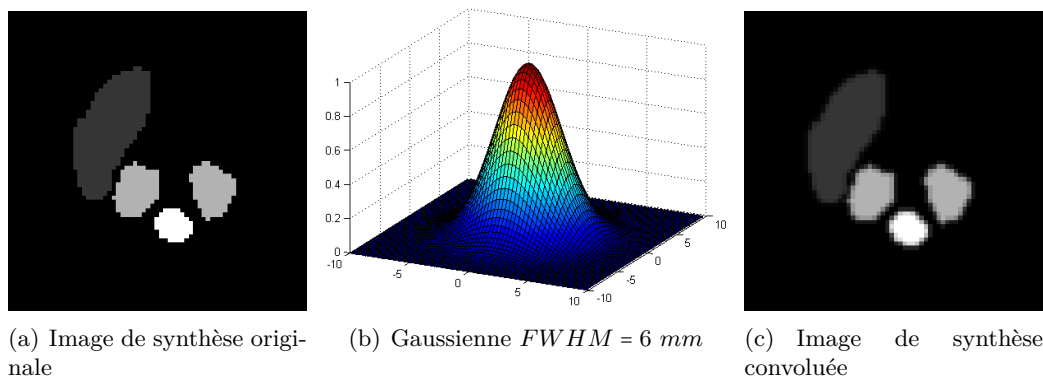


Figure 1.1 – Illustration de l'influence de la convolution 2D d'une image synthétique avec une gaussienne. La taille des pixels sur les images (a) et (c) fait environ  $4 \times 4 \text{ mm}^2$ .

Soit  $F_{max}$ , la fréquence maximale que peut restituer le système de détection. Le fait de numériser le signal impose d'utiliser une fréquence d'échantillonnage  $F_e$ , où  $F_e = \frac{1}{a}$ ,  $a$  étant la plus grande dimension en mm du voxel. Pour restituer au mieux  $F_{max}$ ,  $F_e$  doit vérifier le

théorème de Nyquist-Shannon :

$$F_e \geq 2F_{max}. \quad (1.1)$$

La résolution spatiale et l'échantillonnage choisi a pour conséquence ce que l'on nomme Effet de Volume Partiel (EVP). Il correspond à une contamination des structures voisines.

Le bruit désigne les informations parasites qui viennent dégrader le signal. Ces informations parasites, enregistrées par le système de détection, propagées voire amplifiées par la reconstruction de l'image, se traduisent par une variation d'intensité des voxels au sein d'une région homogène. L'information obtenue devient alors entachée d'incertitude.

#### 1.1.1.1.2 Imagerie médicale 3D

Depuis les années 70, l'analyse *in vivo* du corps humain permet sa représentation en une image à trois dimensions. Ce type d'images est représenté selon une série de coupes et permet de visualiser, selon la modalité utilisée, l'anatomie ou le fonctionnement physiologique des tissus. L'imagerie par TomoDensitoMétrie (TDM), par échographie et l'Imagerie par Résonance Magnétique (IRM) sont notamment des modalités permettant la visualisation de l'anatomie. On peut, en outre, citer des modalités d'imagerie fonctionnelle telles que l'imagerie par Tomographie d'Émission de Positons (TEP), par Tomographie d'Émission Mono-Photonique (TEMP) et l'Imagerie par Résonance Magnétique fonctionnelle (IRMf). Très diverses et complémentaires, ces modalités sont utilisées en fonction de la pathologie que l'on souhaite mettre en évidence.

Les modalités auxquelles nous nous intéressons tout particulièrement, dans le cadre de ce travail, portant sur le traitement du cancer pulmonaire par radiothérapie externe sont l'imagerie anatomique TDM et l'imagerie fonctionnelle TEP. Ces deux modalités ont plusieurs points en commun. Elles sont basées sur une :

- Imagerie photonique : le signal enregistré correspond à des photons ( $X$  ou  $\gamma$ ) d'énergie comprise entre 0 et 511  $keV$ . Ces photons interagissent avec la matière (tissus biologiques et détecteurs) selon les mêmes phénomènes physiques dont la probabilité de survenue dépend de l'énergie des photons et de la densité du milieu traversé.
- Reconstruction tomographique des images : le signal acquis correspond à une série de mesures réalisées tout autour du patient. Chaque image est appelée projection. Ensuite, l'ensemble des projections sont reconstruites à l'aide d'un algorithme de reconstruction tomographique afin d'obtenir un ensemble de coupes 2D formant un volume.



## Interaction des photons avec la matière

Compte tenu de l'énergie des photons mis en jeu en imagerie médicale, les deux principales interactions des photons avec la matière sont l'effet photoélectrique et l'effet Compton. Ces phénomènes résultent de l'interaction du photon incident avec un électron du cortège électronique d'un atome du milieu traversé.

Lors de l'effet photoélectrique, le photon incident transmet toute son énergie à l'électron. Il est totalement absorbé.

Lors de l'effet Compton, le photon incident transmet seulement une partie de l'énergie à l'électron. Il en résulte une diminution de son énergie et une modification de sa trajectoire, d'où également le nom de diffusion Compton donné à cet effet.

La proportion entre effet photoélectrique et effet Compton est fonction de l'énergie du photon et du numéro atomique du milieu qu'il traverse comme présenté Figure 1.2. À basse énergie, et lorsque la densité du milieu traversé est élevée, l'effet photoélectrique prédomine. L'effet Compton, en revanche, prédomine lorsque la densité du milieu traversé est faible et que l'énergie est intermédiaire.

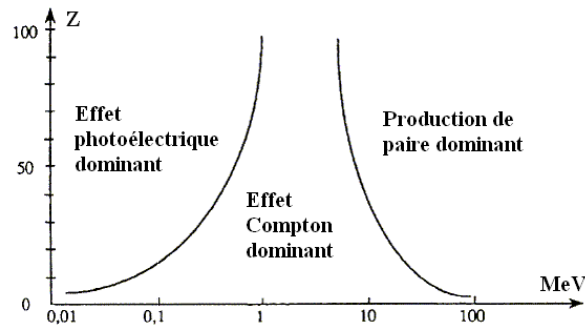


Figure 1.2 – Courbes représentant les dominances entre effet photoélectrique, effet Compton, et production de paire en fonction de l'énergie du photon et du numéro atomique du milieu qu'il traverse. Notons que la production de paire est un phénomène que l'on ne rencontre pas en imagerie médicale étant donnée la faible énergie des photons émis.

## Phénomène d'atténuation

La présence d'interactions entre les photons et la matière provoque un phénomène dit d'atténuation. Ce phénomène correspond à une diminution du nombre de photons.

Soit  $N_0$  la quantité de photons émis depuis une source. La quantité de photons  $N$  présente à l'issue de sa traversée dans un milieu d'épaisseur  $d$  (en cm) est donnée par la fonction exponentielle :

$$N = N_0 \exp\left(-\int_0^d \mu(x) dx\right) \quad (1.2)$$

où  $\mu(x)$ , exprimé en  $cm^{-1}$ , est le coefficient d'atténuation linéique en  $x$  du milieu traversé. Ce coefficient est fonction de l'énergie des photons et de la densité du milieu traversé.

En imagerie médicale, à la traversée d'un tissu dense tel que l'os, l'atténuation résulte principalement de l'effet photoélectrique. En revanche, à la traversée d'un tissu mou, l'atténuation se fera principalement par effet Compton. En outre, plus importante est la densité du milieu, plus importante est la quantité de photons absorbés.

### 1.1.2 Principe de l'imagerie anatomique TDM

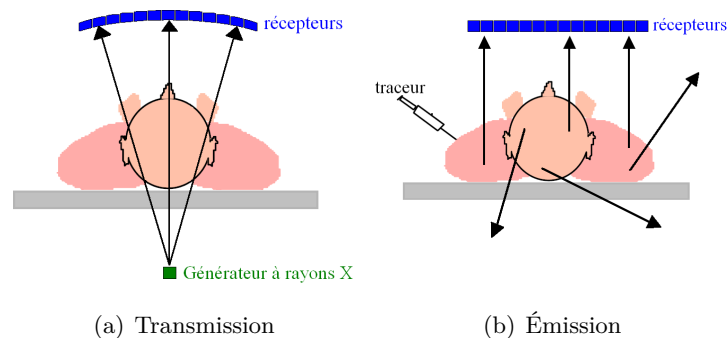


Figure 1.3 – Illustration des principes de transmission et d'émission pour l'obtention de signaux en imagerie médicale.

L'imagerie TDM est une technique d'imagerie par rayons X. Elle est dite de transmission (Figure 1.3(a)). Son principe consiste en l'envoi d'un faisceau de rayons X, qui est ensuite réceptionné après la traversée du patient. Lors de cette traversée, le faisceau est plus ou moins atténué en fonction de la densité des tissus traversés selon la relation 1.2, puis mesuré. Le système d'obtention d'images par rayons X est composé d'un générateur à rayons X et de plusieurs récepteurs (barrettes de détection). La Figure 1.4 présente l'émission et la réception d'un faisceau par le générateur à rayons X et les barrettes de détection tournant mutuellement autour du patient. Notons qu'un faisceau sera peu atténué à la traversée d'un poumon, et fortement atténué à la traversée d'un os. Cette propriété physique est à la base du contraste de l'imagerie TDM.

#### 1.1.2.1 Générateur de rayons X

L'émission du faisceau de rayons X est effectuée par l'intermédiaire d'un tube à rayons X. Ce tube est constitué d'une ampoule comptant deux électrodes entre lesquelles est présente une forte différence de potentiel. Un courant d'électrons se produit alors de la cathode vers l'anode. Les atomes à la surface de l'anode freinent les électrons, produisant par rayonnement de freinage une émission de rayons X. Certains de ces rayons produisent une excitation des




Figure 1.4 – Schéma d'acquisition d'un signal TDM. Le générateur de rayons X engendre une émission de photons X qui, lors de la traversée dans les tissus, sont plus ou moins atténués avant d'arriver au niveau des détecteurs. La rotation mutuelle du générateur à rayons X et des barrettes de détection permet l'obtention d'un signal tout autour du patient.

atomes de l'anode, induisant une réémission de rayons X caractéristiques par le phénomène de fluorescence. Soit  $V$  la tension appliquée aux bornes du tube, on obtient un spectre de photons X d'énergie allant de 0 à  $V$  keV. En imagerie TDM, la tension appliquée varie entre 100 et 240 kV.

Lorsque le faisceau de rayons X passe au travers du patient, une partie est atténuée selon la relation 1.2. Afin de mesurer cette atténuation, il est important de connaître la quantité de photons émis. Celle-ci peut être estimée étant donnée sa proportionnalité avec la quantité d'électrons envoyés à la cathode. L'imprécision de cette estimation est de 0,5%.

### 1.1.2.2 Système de détection

La détection des photons X émis depuis la source d'émission est effectuée par des petits capteurs (1,25 cm de côté) juxtaposés pour former une barrette de détection dans le sens transverse. Plusieurs barrettes permettent l'acquisition de plusieurs projections simultanément. Un ensemble de projections est donc obtenu à l'issue de la rotation simultanée à  $180^\circ$  l'un

de l'autre du tube et des barrettes, indiquant en chaque position la proportion de rayons X atténués.

### 1.1.3 Principe de l'imagerie fonctionnelle TEP




Figure 1.5 – Schéma représentant le principe d'acquisition des images TEP. Après l'injection du radiopharmaceutique au patient, les photons émis en coïncidence depuis celui-ci sont détectés par les couronnes de détecteurs.

L'imagerie par Tomographie d'Émission de Positons donne une information fonctionnelle relative aux tissus biologiques. Le principe est d'injecter au patient un radiopharmaceutique ou radiotracteur. Celui-ci est constitué d'un noyau radioactif émetteur de positons fixé sur une molécule pharmaceutique caractéristique d'un processus physiologique. Cette technique d'imagerie est dite d'émission car les photons sont directement émis au sein du patient (Figure 1.3(b) et Figure 1.5).

#### 1.1.3.1 Noyau radioactif

En imagerie TEP, l'isotope couramment utilisé est le fluor 18 ( $^{18}\text{F}$ ) émetteur de positons  $\beta^+$ . Après un parcours moyen de 0,6 mm lorsque la matière traversée est de l'eau, le positon s'annihile avec un électron. Il en résulte l'émission de deux photons  $\gamma$  opposés à  $180^\circ \pm 0,25^\circ$ , ayant chacun une énergie de 511 keV. Ces photons sont émis en coïncidence (Figure 1.6).




Figure 1.6 – Schéma décrivant le principe de l'émission de positons ( $^{18}\text{F}$ ) et du phénomène d'annihilation avec émission de deux photons  $\gamma$  de 511 keV.

### 1.1.3.2 Radiopharmaceutiques

#### 1.1.3.2.1 $^{18}\text{F}$ FDG

En imagerie TEP, le radiopharmaceutique (ou radiotracteur) le plus communément utilisé est le  $^{18}\text{F}$ FDG ( $^{18}\text{Fluoro-Déoxy-Glucose}$ ). Cette molécule, voisine du glucose, témoigne du métabolisme glucidique de la cellule. Les cellules tumorales ayant un métabolisme glucidique plus important que les cellules saines, les lésions cancéreuses sont caractérisées par une forte fixation de ce radiopharmaceutique. Dans la Figure 1.7(a), on peut observer une importante fixation du  $^{18}\text{F}$ FDG au niveau de la tumeur située dans le poumon gauche.

#### 1.1.3.2.2 $^{18}\text{F}$ FLT

La  $^{18}\text{F}$ FLT ( $^{18}\text{F-Fluoro-L Thymidine}$ ) est un radiotracteur témoignant de la prolifération cellulaire. Sa captation reflète essentiellement l'activité de la Thymidine Kinase 1 qui est augmentée dans les cellules tumorales (Figure 1.7(b)). Une forte fixation de  $^{18}\text{F}$ FLT témoigne d'une importante prolifération cellulaire. En radiothérapie standard, les patients bénéficient d'un traitement à raison d'une séance par jour. En cas de forte prolifération cellulaire, il pourrait être envisagé un traitement à raison de deux séances par jour.

D'après [Roels *et al.*], la  $^{18}\text{F}$ FLT semble, dans le cadre du cancer rectal, posséder une certaine corrélation avec le traceur  $^{18}\text{F}$ FDG. Plus généralement, les cellules proches des tumeurs peuvent être inflammées et consommer du glucose. Le  $^{18}\text{F}$ FDG n'est, dans ce cas de figure, pas un bon prédicteur du volume tumoral fonctionnel, alors que la  $^{18}\text{F}$ FLT aurait l'avantage de ne fixer que les cellules tumorales.




Figure 1.7 – Coupes TEP au  $^{18}\text{F}$ FDG (témoin du métabolisme glucidique), à la  $^{18}\text{F}$ FLT (témoin de la prolifération cellulaire), et au  $^{18}\text{F}$ FMiso (témoin de l'hypoxie) d'un patient présentant une tumeur au poumon gauche.

### 1.1.3.2.3 $^{18}\text{F}$ FMiso

Le  $^{18}\text{F}$ FMiso ( $^{18}\text{F}$ Fluoro-Misonidazole) est un traceur de l'hypoxie<sup>1</sup>. Bien que d'autres traceurs de l'hypoxie existent, la capacité du  $^{18}\text{F}$ FMiso à accumuler la radioactivité dans les zones pauvres en oxygène est considérée comme satisfaisante [MICAD, 2005]. C'est le traceur le plus référencé dans la littérature. L'hypoxie, souvent présente dans les tumeurs étant donnée leur mauvaise vascularisation (Figure 1.7(c)), est responsable d'une radio résistance [Eschmann *et al.*, 2005; Thorwarth *et al.*, 2005], d'où l'intérêt du  $^{18}\text{F}$ FMiso pour le traitement des lésions par radiothérapie externe. Dans [Lee *et al.*, 2008; Rajendran *et al.*, 2006; Thorwarth *et al.*, 2007], les auteurs ont proposé de tirer partie de la TEP au  $^{18}\text{F}$ FMiso afin d'augmenter la dose d'irradiation dans les cellules hypoxiques. Il est encore aujourd'hui difficile de conclure sur l'efficacité du traitement étant donné le faible nombre de patients considérés dans ces études récentes, mais il existe actuellement un réel intérêt pour ces nouvelles modalités de traitement.

### 1.1.3.3 Système de détection

Les détecteurs, permettant la détection des photons, sont composés de cristaux scintillants couplés à des photomultiplicateurs. La réception d'un photon dans un cristal, par effet photoélectrique ou Compton, cède la totalité ou une partie de son énergie aux électrons. Ces électrons génèrent alors un mécanisme de scintillation dont l'énergie lumineuse est proportionnelle à l'énergie déposée dans le cristal. Le photomultiplicateur a alors pour objectif de convertir cette énergie lumineuse en un signal électrique en sortie proportionnel à l'énergie déposée dans le cristal.

1. Manque d'oxygénation des cellules.

Le fait que deux photons soient émis simultanément après annihilation est une information permettant l'estimation du lieu de désintégration le long de la ligne de propagation des deux photons. En mode 3D, la détection des photons est effectuée par plusieurs couronnes de détecteurs.

On nomme lignes de réponse ou propagation (LOR pour *Line Of Response*), une ligne dans l'espace tridimensionnelle où deux photons ont été détectés et semblent provenir d'une même annihilation. La Figure 1.8(a) donne un exemple d'une LOR dont les photons sont dits en coïncidence vraie, c'est à dire provenant d'une même annihilation et parmi lesquels aucun n'a subi de déviation due à des interactions Compton.

La détection d'une coïncidence fortuite (Figure 1.8(c)), résulte de la détection de deux photons issus de deux annihilations différentes que le système d'acquisition ne parvient pas à distinguer. Afin de limiter l'enregistrement des coïncidence fortuites, on utilise une fenêtre temporelle la plus courte possible (quelques nanosecondes), l'objectif étant de ne comptabiliser que les paires de photons qui parviennent aux détecteurs à des temps très proches.

Sur les imageurs TEP récents, un système électronique mesure la durée séparant l'enregistrement des deux événements. Cette durée s'appelle le *temps de vol*. En plus de la LOR, il permet d'avoir une estimation de la position de l'annihilation et d'améliorer ainsi la résolution spatiale du système de détection. Nos travaux n'ont pas été réalisés sur une caméra *temps de vol*.

Le phénomène de diffusion Compton se produit en imagerie TEP et provoque ce que l'on appelle des coïncidences diffusées (Figure 1.8(b)). L'utilisation d'une fenêtre en énergie centrée sur 511 keV permet de réduire la quantité de coïncidences diffusées.

Une coïncidence fortuite (Figure 1.8(c)) correspond à l'enregistrement de deux événements provenant de deux lieux d'annihilation différents, dans une même fenêtre temporelle.

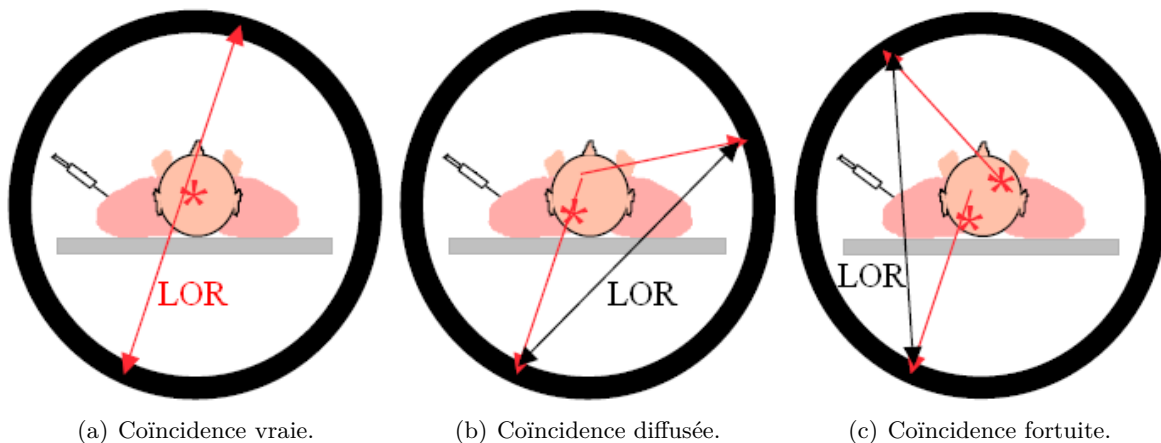


Figure 1.8 – Types de coïncidences enregistrées par le système de détection.

Étant donnés les caractéristiques de l'appareillage et les phénomènes physiques mis en jeu, le signal acquis ne correspond pas à la totalité du signal traversant les détecteurs. Le temps mort notamment correspond à la durée de décroissance de la lumière au sein d'un cristal. Pendant ce temps, il est impossible d'enregistrer d'autres événements sur ce même cristal.

Le phénomène d'atténuation pose également un problème en imagerie TEP. En effet, l'atténuation varie en fonction de l'épaisseur des milieux traversés, produisant alors une sous-évaluation du nombre de photons au niveau des structures profondes. Cependant, lorsque l'on dispose d'un appareil hybride permettant de faire l'acquisition lors d'un même examen d'imageries TDM et TEP, il est possible de tirer parti de l'information anatomique TDM pour effectuer une correction du phénomène d'atténuation en TEP.

#### 1.1.4 Reconstruction Tomographique

La reconstruction tomographique consiste en l'obtention d'une représentation tridimensionnelle du paramètre anatomique ou fonctionnel observé à partir de l'ensemble des projections obtenues à de multiples angles. En imagerie TEP, la résolution mathématique de ce problème est très voisine de la résolution mathématique en imagerie TDM. Nous présentons les deux principales méthodes de reconstruction d'images en nous limitant à l'imagerie TEP, et selon un processus 2D pour en simplifier la présentation, alors qu'en imagerie TEP, le processus est 3D.

À partir d'un signal  $f(x, y)$  d'une coupe 2D (en coordonnées cartésiennes) d'un objet contenant une région radioactive (Figure 1.9), un ensemble de projections monodimensionnelles 1D sont obtenues. Une projection  $p(\theta, u)$  correspond à l'intégrale sur  $v$  du signal étant donné un angle  $\theta$  et une position  $u$ . Une projection, en chaque point  $u$ , correspond ainsi à la somme de toutes les LOR rencontrées le long de l'axe  $v$ .

Dans un premier temps, on procède au rangement des projections en sinogrammes (Figure 1.10), où chaque ligne d'un sinogramme correspond à une projection à un angle donné. En clinique, on préfère des algorithmes 2D avec une reconstruction coupe par coupe. Les sinogrammes, correspondant à des données acquises en 3D, sont réarrangés avant d'effectuer la reconstruction en 2D. Le principal algorithme de réarrangement est l'algorithme FORE (*Fourier REbinding*) [Defrise *et al.*, 1997].

L'objectif de la reconstruction tomographique est, à partir du sinogramme contenant l'ensemble des projections, de reconstruire le signal tridimensionnel. La reconstruction tomographique est donc un problème inverse. On trouve deux familles de méthodes de reconstruction des images. L'une est analytique et l'autre est algébrique. Les méthodes analytiques reposent



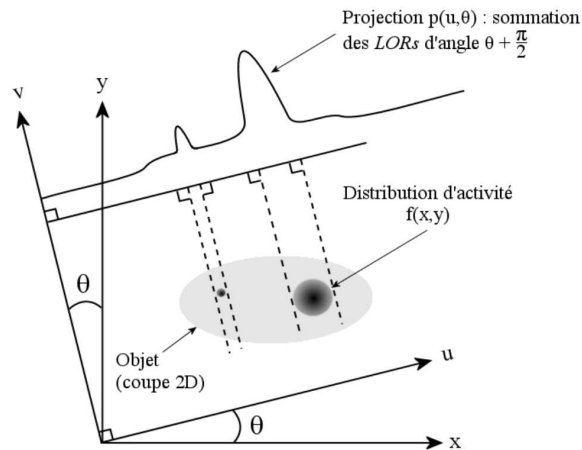


Figure 1.9 – Principe d'obtention des projections. Le signal  $f(x, y)$  en coordonnées cartésiennes, est projeté selon un angle  $\theta$  sur un profil. Le nouveau signal  $p(\theta, u)$  correspond ainsi à une projection de la distribution d'activité  $f(x, y)$  sous l'angle d'incidence  $\theta$ .

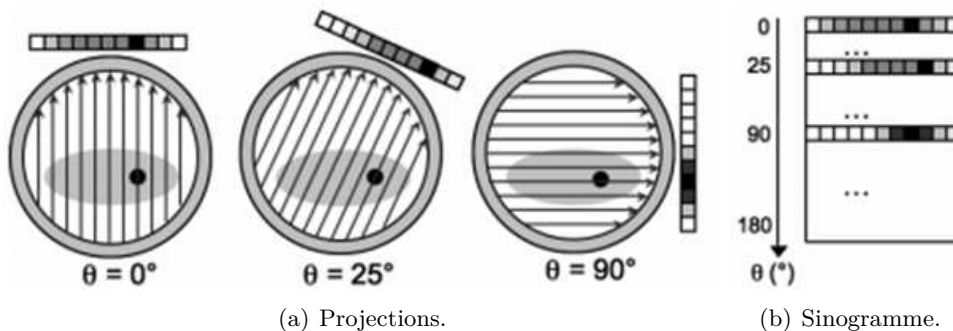


Figure 1.10 – Principe de construction d'un sinogramme. Les projections sont acquises tout autour du patient, puis rangées en une matrice appelée sinogramme où chaque ligne correspond à une projection à un angle donné.

sur la rétroprojection du signal acquis. Les méthodes algébriques reposent sur l'estimation de l'image à reconstruire. Dans cette section, nous présenterons la méthode analytique dite par rétroprojection filtrée (FBP pour *Filtered Back Projection*), ainsi que la méthode algébrique OSEM (pour *Ordered Subset Expectation Maximization*) [Hudson et Larkin, 1994] en raison de leur utilisation très courante en clinique.

#### 1.1.4.1 Méthode FBP

La méthode de reconstruction FBP est une méthode analytique de reconstruction d'images à partir de projections. Basée sur la transformée de Radon, la rétroprojection filtrée utilise de plus la transformée de Fourier.

À partir d'informations dans des coordonnées cartésiennes, il est possible de déterminer les projections du signal à un angle donné. La transformée de Radon permet notamment de

déterminer les projections à de multiples angles. Elle est donnée par :

$$p(\theta, u) = \int_{-\infty}^{+\infty} f(u \cos \theta - v \sin \theta, u \sin \theta + v \cos \theta) dv, \quad (1.3)$$

où  $p(\theta, u)$  correspond à une projection selon un angle  $\theta$  et une position  $u$ . L'objectif de la reconstruction tomographique est de déterminer le signal en coordonnées cartésiennes étant données les projections acquises. Néanmoins, l'inversion directe de la transformée de Radon ne permet pas de retrouver le signal dans les données cartésiennes. Celle-ci induit en effet des artéfacts en étoile sur l'image reconstruite. Ce problème est résolu par le théorème de la coupe centrale :

$$\begin{aligned} \iint_{-\infty}^{+\infty} f(u \cos \theta - v \sin \theta, u \sin \theta + v \cos \theta) \exp^{-i2\pi\rho u} dudv \\ = \iint_{-\infty}^{+\infty} f(x, y) \exp^{-i2\pi(x\rho \cos \theta + y\rho \sin \theta)} dx dy \end{aligned} \quad (1.4)$$

où  $f(x, y)$  correspond au signal à reconstruire. Ce théorème signifie que la transformée de Fourier monodimensionnelle des projections est l'exact équivalent de la transformée de Fourier bidimensionnelle du signal à reconstruire dans les coordonnées cartésiennes. Il suffit donc pour reconstruire le signal, d'effectuer la transformée de Fourier monodimensionnelle des projections, puis d'effectuer la transformée de Fourier inverse bidimensionnelle. Étant donné le changement d'espace, cette procédure nécessite un changement de variables qui induit un filtrage avec un filtre rampe. Notons que ce filtrage tend à amplifier les hautes fréquences. Une solution pour réduire cette amplification consiste alors à filtrer, dans le domaine fréquentiel, le signal avec un filtre passe-bas, d'où l'appellation de la méthode de reconstruction par rétroprojection filtrée.

Cette méthode a tendance à amplifier le bruit au niveau des hautes fréquences et à lisser les images. Cependant, elle est intéressante pour sa rapidité d'exécution.

#### 1.1.4.2 Méthode OSEM

La méthode de reconstruction nommée OSEM est une extension de la méthode MLEM (*Maximum Likelihood Expectation Maximization*) qui repose sur l'algorithme d'estimation non supervisé *Expectation Maximization* [Lange et Carson, 1984]. La méthode MLEM fonctionne de la manière suivante :

Soient  $f$  l'ensemble des voxels d'une coupe à reconstruire et  $R$  la matrice correspondant à l'opérateur de projection. L'ensemble des projections noté  $p$  vérifie la relation :

$$p = Rf. \quad (1.5)$$

On a ainsi un système de  $N$  équations linéaires à  $N$  inconnues,  $N$  correspondant au nombre de voxels de l'image à reconstruire. Ce problème est mathématiquement *mal posé*, car les projections sont entachées d'un bruit statistique, et il n'existe pas de solution juste au problème. L'idée est d'avoir une approche statistique de la reconstruction de l'image par itérations successives, d'où le nom de reconstruction itérative donné généralement à ces méthodes.

L'algorithme MLEM estime itérativement les projections, et ainsi le signal  $f(x, y)$  à reconstruire. Celui-ci repose sur l'estimation, à chaque itération  $i$ , des projections  $\hat{p}^i$  :

$$\hat{p}^i = Rf^i. \quad (1.6)$$

À partir de l'ensemble  $p$  des projections obtenues durant l'acquisition,  $\frac{p}{\hat{p}^i}$  donne une mesure de l'erreur d'estimation des projections. Cette mesure permet de mettre à jour, à l'itération suivante, les valeurs des voxels :

$$f^{i+1} = f^i R^t \frac{p}{\hat{p}^i}, \quad (1.7)$$

où  $R^t$  est la matrice transposée de  $R$ . Ainsi, l'algorithme fonctionne en effectuant de manière itérative, l'estimation des projections, le calcul de l'erreur sur l'estimation, puis la mise à jour de l'image à reconstruire. Notons qu'avant la première itération, l'image est initialisée en une valeur constante. Par ailleurs, il faut noter que plus la quantité d'itérations est importante, meilleure est la restitution des hautes fréquences. Cependant, lorsque le nombre est trop important, l'algorithme diverge car génère du bruit.

La matrice  $R$ , correspondant à l'opérateur de projection, contient des poids relatifs à la contribution des voxels aux différentes projections. Cette matrice dépend des caractéristiques de l'appareillage et peut être construite de manière théorique ou par l'intermédiaire du déplacement d'une petite source ponctuelle dans le tomographe.

La grande quantité de projections et le caractère itératif de l'algorithme engendrent des temps de calcul importants. La méthode OSEM a été introduite afin d'accélérer le processus de reconstruction. Elle fonctionne de la même manière que l'algorithme MLEM, mais plutôt que de traiter l'ensemble des projections lors de chaque itération, elle considère des sous-ensembles ordonnés de projections en changeant à chaque itération le groupe de projections (Figure 1.11). Cela permet d'alléger sa complexité calculatoire. Il a été montré l'équivalence de l'image obtenue entre l'algorithme MLEM ( $n$  itérations) et l'algorithme OSEM ( $s$  sous-ensembles,  $i$  itérations) avec  $n = s \times i$ . Le temps de calcul est divisé d'un facteur  $s$  [Kamphuis *et al.*, 1996].




Figure 1.11 – Schéma présentant la décomposition d'un ensemble de huit projections en deux sous-ensembles de quatre projections. Cette décomposition est utilisée dans l'algorithme de reconstruction tomographique OSEM

Les méthodes de reconstruction itératives peuvent se faire en 3D, mais les algorithmes sont complexes.

Les méthodes de reconstruction itératives telles que MLEM et OSEM ont été introduites dans le but de réduire les artéfacts en étoile autour des régions de forte intensité que l'on rencontre avec la méthode FBP. De plus, même en l'absence d'une importante quantité de projections, leur performance reste élevée. Par contre, les temps de calcul sont plus longs qu'avec l'algorithme FBP.

## 1.1.5 Caractéristiques des images TEP/TDM reconstruites

### 1.1.5.1 Les images TDM

#### 1.1.5.1.1 Reconstruction

L'algorithme principalement utilisé en TDM est l'algorithme FBP en raison du volume des données à reconstruire et des temps de calcul.

#### 1.1.5.1.2 Origine du contraste

Après reconstruction, à chaque voxel  $V_i$  est associée une valeur parmi un ensemble de valeurs définies sur une échelle d'*Unités Hounsfield* ( $UH$ ). L'information  $I_{V_i}$  contenue dans chaque voxel est fonction du coefficient linéique d'atténuation  $\mu$  du tissu tel que :

$$I_{V_i} = \frac{\mu_{tissu} - \mu_{eau}}{\mu_{eau}} \times 1000 \quad (1.8)$$

Les images TDM offrent une vue anatomique en coupe des organes et permettent une différenciation nette entre l'air ( $\sim -1000 UH$ ), la graisse ( $\sim -20 UH$ ), les tissus mous ( $\sim 50 UH$ ) et l'os ( $> 100 UH$ ). Elle permet également de différencier le poumon de l'air, la graisse des tissus mous, ainsi que l'os spongieux de l'os dense. La Figure 1.12 présente la gamme des valeurs  $UH$  que l'on rencontre dans les tissus biologiques. Comme nous pouvons le voir, la différenciation des tissus mous est très délicate et est source d'imprécision. La seule connaissance des  $UH$  des voxels

ne permet pas, en effet, de faire cette différenciation et il devient alors nécessaire d'intégrer une connaissance extérieure relative à la position des organes. L'expert, par sa connaissance *a priori*, est notamment capable de faire cette différenciation. En revanche, dans le souhait de reconnaître automatiquement les différents organes, on peut chercher à recalcrer un atlas anatomique avec la séquence d'images TDM [Han *et al.*, 2008].

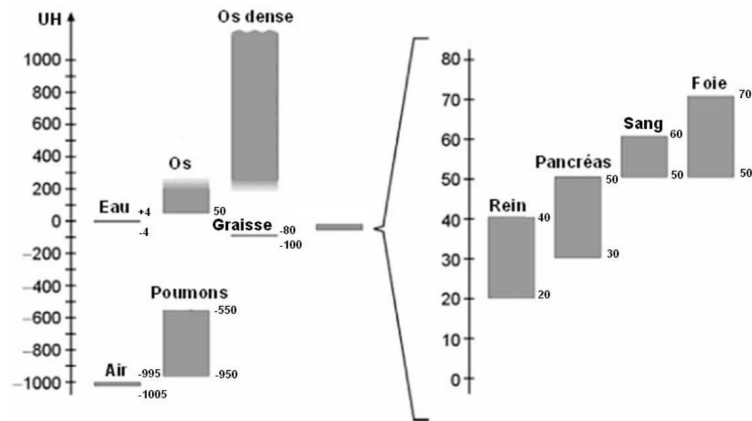
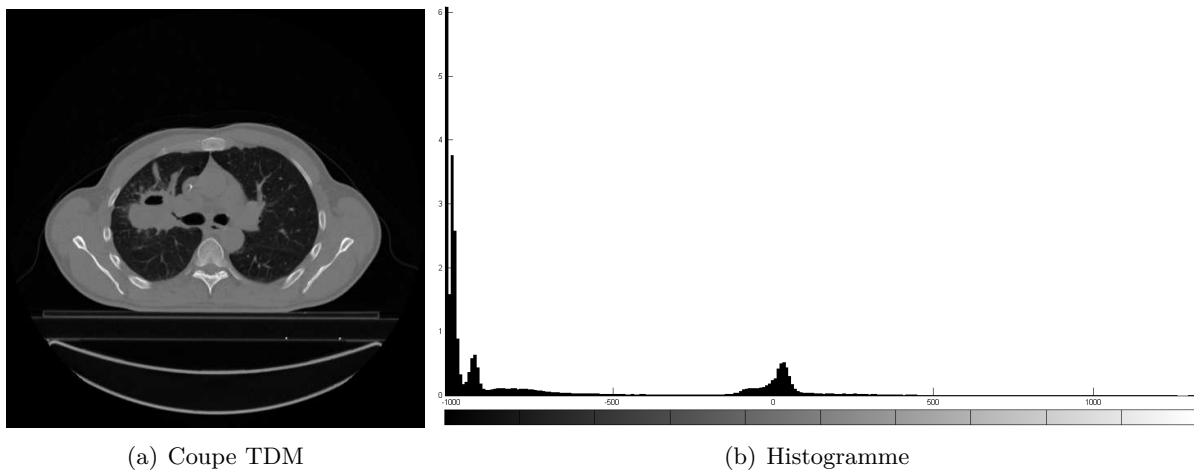


Figure 1.12 – Gamme des valeurs  $UH$  rencontrée en imagerie TDM.



(a) Coupe TDM

(b) Histogramme

Figure 1.13 – Coupe transverse TDM d'un patient atteint d'un cancer pulmonaire droit, et son histogramme associé.

L' $UH$  moyenne d'une tumeur est incluse dans la plage des valeurs que prennent les tissus mous, ce qui rend parfois compliquée la délimitation de la tumeur.

### 1.1.5.1.3 Caractéristiques des images

Les principales caractéristiques des images, comme nous l'avons vu au paragraphe 1.1.1.1.1, sont le bruit et l'effet de volume partiel.

## Bruit

La Figure 1.14(a) correspond à une coupe TDM d'un fantôme de Jaszczak<sup>2</sup> où de l'eau et de l'air sont respectivement présentes à l'intérieur et à l'extérieur du cylindre. On constate que le bruit, présent dans la région d'intérêt tracée sur l'image du fantôme, est faible (Figure 1.14(b)). Il s'étend approximativement à  $\pm 30$   $UH$ .

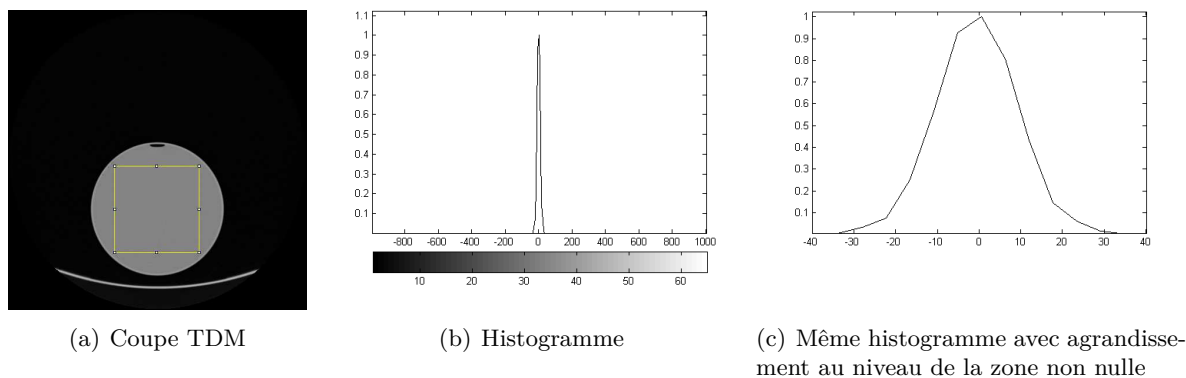


Figure 1.14 – Coupe transverse TDM issue de l'acquisition d'un fantôme de Jaszczak et l'histogramme associé à la région d'intérêt sélectionnée.

## Effet de volume partiel

La Figure 1.15 présente une coupe d'un fantôme de Jaszczak, ainsi que le profil correspondant au segment tracé sur l'image. Ce profil compte trois régions que sont l'eau, le plastique et l'air avec respectivement des  $UH$  proches de 0, 150 et -1000. Le profil montre que la transition d'une classe à une autre est relativement bien tranchée en raison de la bonne résolution spatiale de l'imagerie TDM ( $\sim 2$   $mm$ ), et donc de la faible présence d'effet de volume partiel. La taille des voxels est proche de  $0,97$   $mm$  de manière à respecter le théorème de Nyquist-Shannon.

### 1.1.5.2 Les images TEP

#### 1.1.5.2.1 Reconstruction

L'algorithme très largement utilisé en imagerie TEP est l'algorithme OSEM, pour son aptitude à induire moins de bruit que la méthode FBP (section 1.1.4.2). Itératif, cet algorithme est plus lourd que la méthode FBP en terme de temps de calcul. Cette durée est actuellement acceptable en clinique pour l'imagerie TEP, mais pas pour l'imagerie TDM en raison des différences de taille des matrices à reconstruire.

2. Un fantôme est un objet pouvant contenir des sphères incluant le traceur  $^{18}F$ FDG, et dont on a fait l'acquisition afin d'obtenir les images.

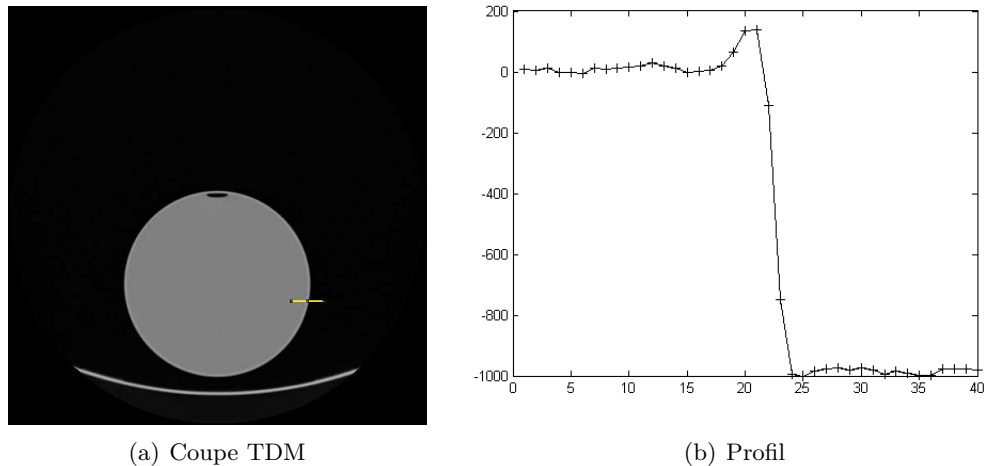


Figure 1.15 – Coupe transverse TDM issue de l'acquisition d'un fantôme de Jaszczak et le profil associé au tracé sélectionné.

#### 1.1.5.2.2 Origine du contraste

Le contraste vient de la différence de fixation physiologique du radiotracer entre les tissus biologiques. Il évolue en fonction de la pharmacocinétique du traceur au cours du temps. C'est la raison pour laquelle le produit est administré une heure (pour le  $^{18}\text{F}$ FDG) avant la réalisation de l'examen pour obtenir un contraste entre les tissus sains et pathologiques.

Il est intéressant de normaliser le taux de fixation par l'activité injectée et le poids du patient, qui est une estimation satisfaisante de son volume. La masse volumique du patient étant proche de celle de l'eau, son volume en millilitres peut être considéré comme égal à son poids en grammes. Cette normalisation permet de comparer les taux de fixation d'une population de patients ou d'un même patient lors de deux examens différents. La concentration radioactive normalisée est nommée Standardized Uptake Value (SUV) et est donnée par :

$$\text{SUV} = \frac{\text{fixation (Bq/mL)}}{\text{activité (Bq)/volume (mL)}}.$$

Ainsi, un SUV de 1 correspond à une fixation moyenne dans l'organisme. Un SUV de 10 signifie que les tissus présentent une fixation 10 fois plus importante que la moyenne.

La valeur du SUV pour le  $^{18}\text{F}$ FDG est sensible au taux de glycémie, ce qui peut notamment poser un problème chez les patients diabétiques. Par ailleurs, la vitesse de captation du  $^{18}\text{F}$ FDG par la tumeur varie non seulement en fonction des patients, mais également pour un même patient au cours du suivi thérapeutique [Hamberg *et al.*, 1994].

### 1.1.5.2.3 Caractéristiques des images

Les images TEP ont pour caractéristiques d'être très bruitées et sujet à un important effet de volume partiel.

#### Bruit

Le bruit a pour origine la nature stochastique (loi de Poisson) du phénomène de désintégration, de la reconstruction tomographique et des nombreuses corrections mises en place. Il est d'autant plus présent en imagerie TEP que la quantité de signal reçue au niveau des détecteurs est faible.

La Figure 1.16 présente une coupe TEP d'un fantôme de Jaszczak où de l'eau et de l'air sont respectivement présents à l'intérieur et à l'extérieur du cylindre. L'eau contient du  $^{18}\text{F}$ FDG réparti uniformément. L'histogramme construit à partir de la région d'intérêt sélectionnée présente une importante variation du nombre d'événements enregistrés. Il varie entre 2500 et 6000, illustrant l'importance du bruit en imagerie TEP.

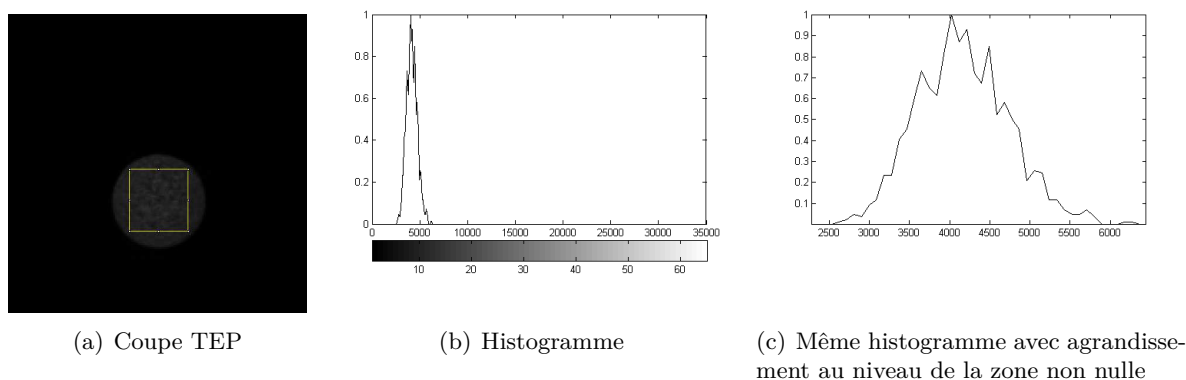


Figure 1.16 – Coupe transverse TEP issue de l'acquisition d'un fantôme de Jaszczak et l'histogramme associé à la région d'intérêt sélectionnée. Acquisition de 3 minutes, algorithme de reconstruction OSEM (4 itérations, 8 subsets), matrice  $168 \times 168$  voxels, *post*-filtrage gaussien de FWHM 5 mm.

#### Effet de volume partiel

L'effet de volume partiel a pour origine la faible résolution spatiale et l'échantillonnage choisi. Il correspond en TEP à deux effets : l'effet *spill-out* et l'effet *spill-over*, qui correspondent respectivement à une sous-estimation de la concentration dans les petites structures, et à une sur-estimation des concentrations dues à la contamination des structures voisines. Du fait de la résolution spatiale limitée en imagerie TEP, l'EVP a une grande importance et engendre une forte imprécision à la transition entre les régions.



Afin de rendre compte de l'effet qu'engendre la mauvaise résolution spatiale, nous avons tracé le profil d'un segment sélectionné sur une image TEP Figure 1.17. La coupe présentée, issue d'un fantôme de Jaszczak, comprend la section d'une sphère dont la radioactivité est huit fois supérieure à la radioactivité qui l'entoure. Malgré ce fort contraste, on peut observer qu'environ deux voxels sont à la transition des zones de différentes fixations, ce qui correspond à une transition de près de 8 mm de largeur. La résolution spatiale est ici de 6,8 mm avec une taille de voxels de  $4,06 \times 4,06 \times 2 \text{ mm}^3$ .




Figure 1.17 – Coupe transverse TEP issue de l'acquisition d'un fantôme de Jaszczak et le profil associé au tracé sélectionné. Acquisition de 3 minutes, algorithme de reconstruction OSEM (4 itérations, 8 subsets), matrice  $168 \times 168$  voxels, *post*-filtrage gaussien de FWHM 5 mm.

### 1.1.5.3 Les images TEP/TDM

Les images TDM et TEP, une fois reconstruites, offrent une vue anatomique et fonctionnelle. Comme les deux examens TDM et TEP sont acquis lors d'un même examen, les deux images sont recalées. Cependant, les images TEP au  $^{18}\text{F}$ FDG, à la  $^{18}\text{F}$ FLT et au  $^{18}\text{F}$ Miso sont acquises à trois instants différents pour un même patient et nécessitent donc d'être recalées. Pour recalier les images TEP multi-traceurs d'un même patient, on utilise une méthode de recalage rigide [Maintz et Viergever, 1998] en se référant à l'information anatomique TDM qui est commune lors des trois examens. Une fois que les paramètres de recalage sont obtenus, ils peuvent être utilisés pour recalier les examens TEP entre eux. Le recalage des images est une étape importante pour la mise en correspondance des différents examens. Cependant, il peut toujours subsister de légers décalages résiduels entre les images TEP multi-traceur.

### 1.1.6 Conclusion

Comme nous l'avons vu dans cette section, les images TDM et TEP sont complémentaires. L'imagerie anatomique permet de visualiser l'anatomie, alors que l'imagerie fonctionnelle permet de visualiser le comportement physiologique par rapport à un pharmacétique.

L'imagerie médicale multimodale est de nos jours de plus en plus utilisée par l'expert médical à des fins de diagnostic, de suivi thérapeutique, ou de traitement par chirurgie, chimiothérapie et par radiothérapie. En oncologie, la multimodalité est utilisée pour permettre à l'expert médical de cibler les éventuelles zones tumorales d'un patient pour *a posteriori* les traiter.

## 1.2 Place de l'imagerie TEP en radiothérapie

### 1.2.1 Principe de la radiothérapie externe

#### 1.2.1.1 Introduction

Trois types de traitement en oncologie existent : la chirurgie, la chimiothérapie et la radiothérapie. Le traitement auquel nous nous intéresserons dans ce manuscrit est la radiothérapie, permettant de traiter près de deux tiers des patients atteints d'un cancer à une étape de leur parcours de soin. Cela représente environ 200 000 nouveaux cas chaque année en France.

La radiothérapie consiste à délivrer une dose d'irradiation de rayonnements ionisants dans les tissus tumoraux afin de les détruire. Le rayonnement est dit ionisant lorsqu'il est capable de déposer assez d'énergie dans les tissus biologiques (interaction directe ou indirecte des rayons avec la matière) pour produire une ionisation (électrons arrachés aux atomes du milieu).

On distingue trois types de traitement par radiothérapie : la radiothérapie dite externe, la curiethérapie et la radiothérapie métabolique. En radiothérapie externe, la source d'irradiation est située à l'extérieur du patient. Pour atteindre la lésion tumorale à détruire, les rayons traversent la peau ainsi que d'autres organes ou tissus sains. En curiethérapie et en radiothérapie métabolique, la source d'irradiation est directement placée à l'intérieur de l'organisme. Le traitement auquel nous nous intéressons est la radiothérapie externe.

Les deux rayonnements les plus couramment utilisés en radiothérapie externe sont les photons de haute énergie (pouvant atteindre les tissus profonds) et les électrons.

Les doses de radiation délivrées se mesurent en gray (Gy). Un gray représente un joule d'énergie absorbée pour une masse de tissus d'un kilogramme. La dose est délivrée au patient en plusieurs séances. On parle alors de radiothérapie fractionnée, où la dose et le fractionnement sont prescrits par le médecin radiothérapeute. Pour une radiothérapie classique, la dose totale

prescrite est délivrée par fractions de 2 Gy : une fraction par jour, cinq jours par semaine, et ce pendant plusieurs semaines (6 à 7 semaines).

En radiothérapie externe, l'objectif est de délivrer une dose maximale dans les volumes cible tumoraux, et minimale dans les tissus périphériques sains. L'augmentation de la dose délivrée au volume cible améliore le contrôle local [Hanks *et al.*, 1985], mais une trop forte dose délivrée aux tissus sains environnants peut engendrer des complications [Emami *et al.*, 1991]. L'étude des effets biologiques des rayonnements ionisants montre qu'un sous-dosage au-delà de 5 % accroît les risques de récurrence du cancer alors qu'un sur-dosage supérieur à 5 % est susceptible d'entraîner des complications cliniques sévères [Dische *et al.*, 1993]. Pour répondre à ces contraintes, le traitement par radiothérapie externe est précédé d'une phase de planification.

### 1.2.1.2 Acquisition des données

La planification du traitement débute par l'acquisition des données anatomiques du patient. Elle est réalisée au moyen d'un scanner de simulation (imagerie TDM). Les images permettent d'une part de définir précisément le volume cible à irradier, et d'autre part les Organes À Risque (OAR) avoisinants qu'il convient de protéger.

### 1.2.1.3 Définition des volumes cible

La définition des volumes cible et des organes à risque est réalisée par le radiothérapeute sur une console de planification de traitement. Elle est faite sur les images TDM de mise en place, c'est à dire acquises dans les mêmes conditions que lors du traitement en terme de positionnement du patient. En plus de l'imagerie TDM, notons que la connaissance de l'histoire naturelle du cancer et des résultats des examens diagnostiques participent à la définition des volumes réalisée par le radiothérapeute. L'*International Commission on Radiation Units and measurements* définit les règles aidant à la planification du traitement. Parmi elles, nous trouvons la définition de différents volumes utilisés pour définir les régions tumorales à traiter, les tissus sains à exclure de l'irradiation et les volumes physiques servant à planifier le traitement.

Les volumes utilisés pour définir les régions tumorales, tels qu'illustrés Figure 1.18, sont les suivants :

- Le GTV (*Gross Tumor Volume*) correspond au volume tumoral macroscopique, et comprend l'ensemble des lésions tumorales visible ou palpable avec les moyens actuels d'imagerie.

- Le CTV (*Clinical Target Volume*) correspond au volume cible anatomique. Il comprend le GTV auquel vient s'ajouter une marge tenant compte des extensions microscopiques habituellement observées sur les pièces d'exérèse chirurgicale.
- L'ITV (*Internal Target Volume*) correspond au volume cible interne. Il comprend le CTV plus une marge tenant compte des mouvements internes des organes telle que la respiration.
- Le PTV (*Planning Target Volume*) correspond au volume cible prévisionnel. C'est une marge de sécurité autour de l'ITV tenant compte des incertitudes de positionnement. Il permet *a posteriori* d'assurer que la dose prescrite est effectivement délivrée sur l'ensemble du CTV.




Figure 1.18 – Définition des différents volumes cibles en radiothérapie.

## 1.2.2 Apport de l'imagerie TEP en radiothérapie

### 1.2.2.1 Introduction

Dans le cas du cancer, l'imagerie TEP au  $^{18}\text{F}$ FDG intervient pour le diagnostic, l'évaluation du stade de la maladie, ainsi que pour la planification du traitement par radiothérapie et le suivi thérapeutique du patient.

### 1.2.2.2 Diagnostic

La TEP au  $^{18}\text{F}$ FDG a un intérêt majeur pour le diagnostic. Sa sensibilité (96,8 %) et sa spécificité (77,8 %) en font un outil performant de diagnostic de malignité [Mac Manus et Hicks,

2008]. Elle permet également d'évaluer l'étendue de l'envahissement tumoral, l'objectif étant de classer les cancers selon leur extension anatomique (classification TNM : Tumeur primitive, ganglions lymphatiques (*Node* en anglais), et Métastases). Ce classement est essentiel pour le choix de la thérapie proposée au patient.

### 1.2.2.3 Définition des volumes cible

L'information fonctionnelle véhiculée par l'imagerie TEP est particulièrement utile à la définition des volumes cible. Son intérêt pour la planification du traitement a très largement été démontré [Mac Manus et Hicks, 2008; Ford *et al.*, 2009] et son utilisation en routine clinique se développe. Comme nous le verrons lors du prochain chapitre, de nombreuses études portent sur l'exploitation de l'information en TEP améliorant significativement la définition des volumes cible.

L'imagerie TEP au  $^{18}\text{F}$ FDG a une meilleure sensibilité et spécificité que l'imagerie TDM. Elle permet d'améliorer la reproductibilité de la définition du GTV, aussi bien en *intra* qu'en *inter*-opérateur [Steenbakkers *et al.*, 2006; Ashamalla *et al.*, 2005; Caldwell *et al.*, 2001]. En outre, il a été montré que la TEP contribue à sensiblement modifier la définition du GTV aussi bien dans sa forme que dans son volume [Ford *et al.*, 2009]. Dans [Ciernik *et al.*, 2003; Fox *et al.*, 2005] les auteurs montrent que l'utilisation combinée de la TEP et de la TDM, par rapport à l'utilisation de la TDM seule, contribue à améliorer la définition du GTV, et peut conduire à la réduction de la dose aux organes à risque.

L'un des enjeux majeurs en radiothérapie porte sur l'amélioration du contrôle loco-régional. Les cellules tumorales étant hétérogènes, c'est à dire ayant des comportements physiopathologiques qui diffèrent (hypoxie, prolifération, densité, perfusion, . . .), la définition de sous-volumes tumoraux pourrait avoir un impact sur le traitement. La notion de BTV (*Biological Target Volume*) [Ling *et al.*, 2000], a été proposée dans le but de définir plusieurs sous-volumes en tirant partie de l'imagerie fonctionnelle. Cette information permet de moduler la délivrance de la dose dans le GTV, en identifiant les zones métaboliquement actives. Cette stratégie thérapeutique est nommée *Dose Painting* [Hall, 2005], et est actuellement en cours de validation [Aerts *et al.*, 2010]. L'émergence de nouveaux radiotraceurs en imagerie TEP devrait jouer un rôle essentiel dans le traitement des tumeurs. Les traceurs  $^{18}\text{F}$ Miso et  $^{18}\text{F}$ FLT, présentés section 1.1.3.2, permettent notamment de définir deux sous-volumes tumoraux respectivement témoins de l'hypoxie et de la prolifération cellulaire, et donc d'envisager un traitement par radiothérapie avec potentiellement une escalade de dose des sous-volumes hypoxiques et une augmentation de la fréquence des séances d'irradiation des sous-volumes hyper-prolifératifs.

#### 1.2.2.4 Suivi thérapeutique

L'imagerie TEP intervient également dans le suivi thérapeutique des patients. Elle permet de distinguer les régions ne présentant pas d'évolution, ou présentant une évolution positive ou négative.

Plusieurs études ont été menées et montrent que la TEP au  $^{18}\text{F}$ FDG fournit une information plus précise et plus précoce sur la réponse au traitement que l'imagerie TDM [Ichiya *et al.*, 1996; Choi *et al.*, 2002; Mac Manus *et al.*, 2003; Weber *et al.*, 2003]. Elle pourrait en outre avoir une valeur pronostique et permettre d'adapter la radiothérapie dans l'objectif de limiter le risque de récurrence [Gupta *et al.*, 2010; de Geus-Oei *et al.*, 2009]. Cependant, la validation de son caractère pronostique, pour une utilisation en routine clinique, nécessite une standardisation des méthodes de quantification. La non-reproductibilité de leur méthode basée sur la SUV, dépendante du protocole d'acquisition, a été démontrée [Berghmans *et al.*, 2008].

### 1.3 Conclusion

Ce chapitre a donné lieu à la présentation de la place de l'imagerie TEP dans le traitement par radiothérapie. Dans un premier temps, le principe d'acquisition de l'imagerie TEP/TDM a été présenté, et a permis de mettre en exergue le principe d'obtention des images fonctionnelles TEP. Elles apportent une information fonctionnelle dépendant du traceur utilisé. À l'issue de leur reconstruction, nous avons en outre pu voir qu'elles sont entachées de bruit et peuvent présenter une résolution spatiale limitée. Dans un second temps, la place de la TEP dans le traitement des lésions tumorales a été présentée. Outre son intérêt pour le diagnostic et le pronostic, l'imagerie TEP a un intérêt majeur pour la délimitation du volume cible et donc pour la mise en place du traitement par radiothérapie externe nécessitant un ciblage précis des volumes lésionnels à irradier. L'utilisation du traceur  $^{18}\text{F}$ FDG permet d'abord d'améliorer la définition du GTV défini à l'aide de l'imagerie de prédilection, la TDM. Ensuite, l'utilisation des traceurs  $^{18}\text{F}$ FLT et/ou  $^{18}\text{F}$ Miso permet la définition de BTV, correspondant à des sous-volumes de la lésion qui peuvent donner lieu à une intensification du traitement dans le cadre de *Dose Painting*.

L'imagerie TEP a un intérêt majeur pour la délimitation du volume cible. De plus, l'utilisation croissante de traceurs implique une augmentation de la quantité d'information examinée par le radiothérapeute pour la mise en place du traitement. Il est donc impératif de mettre en place des outils automatiques pour faciliter la segmentation de ces images et des outils d'aide

à la décision en *Dose Painting*. Étant donné leur résolution spatiale limitée et le bruit présent dans les images, cette tâche semble ardue.

# Chapitre 2

## Segmentation d'images TEP

### Sommaire

---

<b>2.1</b>	<b>Introduction</b>	<b>47</b>
<b>2.2</b>	<b>État de l'art des méthodes de segmentation des lésions</b>	<b>48</b>
2.2.1	Approches par seuillage	49
2.2.2	Approches par croissance de régions	52
2.2.3	Approches dérivatives	53
2.2.4	Modèle déformable	55
2.2.5	Approches probabilistes	56
2.2.6	Approche floue	59
2.2.7	Approche par fusion	61
2.2.8	Méthodes basées sur la texture	61
<b>2.3</b>	<b>Évaluation de sept méthodes de segmentation</b>	<b>63</b>
2.3.1	Matériels et méthodes	63
2.3.2	Analyse des données	66
2.3.3	Résultats	66
<b>2.4</b>	<b>Conclusion</b>	<b>71</b>

---

### 2.1 Introduction

Comme nous l'avons vu dans le précédent chapitre, l'imagerie TEP au  $^{18}\text{FDG}$  est un support important pour le traitement des lésions tumorales par radiothérapie externe. Utilisée en plus de l'imagerie anatomique TDM pour le contourage des lésions tumorales, elle permet notamment de réduire la variance *intra* et *inter*-observateur [MacManus *et al.*, 2007; MacManus et Hicks, 2008]. Cependant, le manque de reproductibilité observé en effectuant le contourage manuel nous entraîne à préférer les méthodes de segmentation automatique.

La segmentation d'images consiste à partitionner une image en régions. Dans le contexte de l'imagerie TEP, l'objectif de la segmentation est de rassembler les voxels qui appartiennent à une lésion. Bien qu'elle soit souvent effectuée de façon manuelle, des méthodes ont été développées



afin de segmenter les images de manière automatique ou semi-automatique. L'objectif est alors d'éviter à l'utilisateur d'effectuer un travail fastidieux tout en donnant un résultat rapide et reproductible. Certaines méthodes cherchent les zones d'intensité homogène correspondant à des régions, alors que d'autres cherchent les brusques variations d'intensité caractéristiques des contours des régions. Dans de nombreuses méthodes de segmentation automatique, les voxels sont considérés comme des individus, ou observations, et la segmentation est alors vue comme un problème de classification d'individus parmi un ensemble de classes. Notons qu'il existe en segmentation des relations spatiales qui lient les voxels d'une même région entre eux. En imagerie, le contexte spatial est alors souvent intégré aux systèmes de classification.

Ce chapitre présente les méthodes proposées dans la littérature pour la segmentation des images TEP. La présentation se focalise sur les images obtenues à partir du traceur  $^{18}\text{FDG}$  largement documenté dans la littérature, mais aussi à partir des traceurs  $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$ . Compte tenu du nombre important de méthodes proposées dans la littérature et l'absence de consensus sur la meilleure méthode, une étude comparative incluant sept de ces méthodes a été menée et sera présentée en fin de chapitre.

## 2.2 État de l'art des méthodes de segmentation des lésions

Nous présentons l'état de l'art des méthodes de segmentation des images TEP au  $^{18}\text{FDG}$  à la  $^{18}\text{FLT}$  et au  $^{18}\text{FMiso}$  dans cette section. Selon l'approche La majorité des travaux porte sur la segmentation des images TEP au  $^{18}\text{FDG}$ . Les images TEP au  $^{18}\text{FMiso}$  et à la  $^{18}\text{FLT}$  relèvent en effet du stade expérimental.

La majorité des travaux traitant de la TEP à la  $^{18}\text{FLT}$  tirent parti de ce traceur pour évaluer la réponse au traitement et reposent souvent sur une analyse du SUV dans la région tumorale. Quelques études ont néanmoins été proposées pour la segmentation de ces images. Les SUV relevés dans des lésions en TEP à la  $^{18}\text{FLT}$  semblent plus faible qu'en TEP au  $^{18}\text{FDG}$  pour des cancers gastriques, pulmonaires et de l'oesophage [Herrmann *et al.*, 2007; Tian *et al.*, 2008; Han *et al.*, 2010; Xu *et al.*, 2011]. Malgré ces faibles SUV, les lésions semblent mieux contrastées en TEP à la  $^{18}\text{FLT}$ , notamment pour les tumeurs cérébrales [Chen *et al.*, 2005]. Bien que les degrés de fixation pour les traceurs  $^{18}\text{FDG}$  et  $^{18}\text{FLT}$  diffèrent, les différents auteurs se réfèrent généralement aux méthodes proposées pour la TEP au  $^{18}\text{FDG}$ . Elles sont basées dans la majeure partie des cas sur le seuillage.

Les particularités des images TEP au  $^{18}\text{FMiso}$  sont la faible fixation du traceur et la faible différence de captation entre les tissus sains et tumoraux [Roels *et al.*]. Le seuillage est également la méthode de segmentation la plus utilisée pour ce traceur.

## 2.2.1 Approches par seuillage

### 2.2.1.1 Principe

Le seuillage est la méthode de segmentation la plus simple à mettre en oeuvre. Elle consiste à binariser une image à partir d'une valeur seuil, c'est à dire à la rendre monochromatique. Cette binarisation est effectuée en assignant à tous les voxels dont l'intensité est inférieure au seuil la valeur 0, et 1 à tous les autres voxels. Ce procédé peut permettre, notamment en imagerie médicale, de séparer les tissus sains des tissus pathologiques. La bonne séparation des tissus repose alors sur le choix de la valeur seuil. Celle-ci peut être déterminée manuellement en se référant par exemple à l'histogramme de l'image, l'histogramme permettant de visualiser la répartition des intensités dans l'image (l'intensité des voxels et leur occurrence d'apparition). Plusieurs études se sont penchées sur la détermination automatique du seuil. Comme nous pourrons le voir section 2.2.1.2.1, les méthodes basées sur le seuillage en imagerie TEP sont spécifiques à ce type d'images.

Bien que le seuillage soit la manière la plus simple de réaliser une segmentation, il fait souvent appel à des méthodes plus complexes afin de déterminer le seuil optimal [Prieto *et al.*, 2012]. Dans [Hu *et al.*, 2001], les auteurs ont proposé de déterminer automatiquement le seuil pour la segmentation d'images TDM. Leur méthode consiste en l'estimation itérative des moyennes des intensités relatives aux deux classes considérées et en la mise à jour du seuil dont la position est à égale distance des deux moyennes. Notons que cette méthode est généralisée par l'algorithme des *k*-moyennes (*k-means*) [MacQueen, 1967].

Le seuillage étant la méthode la plus utilisée dans la littérature, nous présentons ici les méthodes utilisant cette approche en distinguant les trois traceurs  $^{18}\text{FDG}$ ,  $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$ .

### 2.2.1.2 État de l'art

#### 2.2.1.2.1 Images TEP au $^{18}\text{FDG}$

Les méthodes de segmentation utilisant le seuillage ont très largement été proposées dans la littérature pour la segmentation des images TEP au  $^{18}\text{FDG}$ . Dans [Paulino et Johnstone, 2004; Nestle *et al.*, 2005], les auteurs proposent d'utiliser un seuillage fixe fonction du SUV relevé dans la région tumorale. Le seuil choisi est 2,5, ce qui permet aux auteurs de ne sélectionner

que les voxels dont l'intensité, en terme de SUV, sont considérés comme relevant d'une tumeur maligne. Dans [Erdi *et al.*, 1997; Nestle *et al.*, 2005] les auteurs montrent qu'un seuillage fixe dont l'intensité avoisine 40 % de l'intensité maximale relevée dans la région tumorale permet de relativement bien segmenter les lésions supérieures à 4 mL ou de contraste important. En outre, ils proposent d'adapter le seuil lorsque la fixation au sein de la région tumorale est faible ou lorsque la lésion est petite.

Afin d'améliorer la segmentation, notamment des petites lésions, des méthodes automatiques, dont l'objectif est de déterminer le seuil optimal, ont été proposées. Leur principe est d'adapter le seuil en fonction d'un ou deux paramètres caractéristiques. Le seuil et les paramètres sont alors appris lors d'une phase de calibration à partir de données de fantômes pour lesquels les volumes des sphères sont connus. Plusieurs paramètres ont été proposés dans la littérature tels que le volume des lésions [Erdi *et al.*, 1997], le SUV [Black *et al.*, 2004] ou le contraste [Daisne *et al.*, 2003; Nestle *et al.*, 2005]. Notons que dans [Jentzen *et al.*, 2007], un processus itératif est utilisé afin de déterminer le seuil optimal. La comparaison de ces différentes approches dans [Vauclin *et al.*, 2010] montre que le paramètre de contraste offre de meilleurs résultats. En outre, les auteurs proposent d'améliorer la méthode proposée dans [Daisne *et al.*, 2003]. Elle est composée de quatre étapes. À l'initialisation, un volume est créé au sein de la tumeur et permet de calculer la moyenne des intensités dans ce volume et de déterminer un seuil initial  $Th^0$ . Les trois étapes qui suivent sont incluses dans un processus itératif permettant de déterminer le seuil optimal. Soit  $k$  le numéro de l'itération. À partir de  $Th^k$ , la seconde étape de la méthode permet d'extraire le plus grand volume 3D. Il est composé de voxels connexes appartenant à l'hyper-fixation. Ensuite, le contraste entre la région du fond et l'hyper-fixation est mesuré. Étant donnée la présence d'une transition floue entre ces deux régions, notons que les auteurs proposent de laisser une marge de 2 voxels entre elles afin de ne pas biaiser la mesure du contraste. Enfin, la dernière étape permet de mettre à jour la valeur du seuil. Cette méthode, calibrée sur un fantôme de Jaszczak, offre des taux d'erreur faibles. Plus récemment, Prieto *et al.* [2012] ont montré qu'il était possible d'utiliser des méthodes permettant une définition automatique du seuil donnant de bons résultats, sur une validation basée sur des sphères homogènes.

#### 2.2.1.2.2 Images TEP à la $^{18}\text{FLT}$

Dans [de Langen *et al.*, 2009], la segmentation de tumeurs chez neuf patients atteints d'un cancer pulmonaire et six patients atteints d'un cancer ORL (Oto-Rhino-Laryngologie) a été effectuée à l'aide d'un seuillage à 41 % de l'intensité maximale, avec une correction locale

du fond ( $C41\%$ ) [Boellaard *et al.*, 2008]. Dans [Frings *et al.*, 2010], les auteurs proposent de reprendre cette méthode ( $C41\%$ ) et de l'étendre à deux autres seuillages ( $C50\%$  et  $C70\%$ ). Ces auteurs ont également étudié un seuillage fixe à 50 % de l'intensité maximale. Les images TEP à la  $^{18}\text{FLT}$  et au  $^{18}\text{FDG}$  étant toutes deux des images métaboliques de contenu semblable, les auteurs proposent d'évaluer les méthodes sur un même fantôme avec deux contrastes, puis de les appliquer à la fois aux traceurs  $^{18}\text{FDG}$  et  $^{18}\text{FLT}$ . Les résultats sur fantômes montrent, dans un premier temps, que le seuillage  $C41\%$  et le seuillage fixe à 50 % donnent les meilleurs résultats. Cependant, l'étude sur patients semble montrer que le seuillage  $C50\%$  sur-estime moins les lésions, ceci étant dû à l'hétérogénéité de la fixation dans le fond. Les auteurs concluent sur la nécessité de développer une méthode prenant en compte l'hétérogénéité du signal en imagerie TEP. Enfin, plus récemment, ces auteurs ont repris ces travaux et ont proposé une étude plus étendue comparant dix méthodes de segmentation [Cheebsumon *et al.*, 2011]. Deux méthodes correspondaient à des seuillages fixes, trois à des seuillages fixes intégrant une correction locale du fond, deux étaient des méthodes de seuillages adaptatifs, une correspondait à un seuillage fixe du SUV de 2,5, une était une méthode itérative reposant sur la convolution de l'image avec la PSF (*Point Spread Function*), et la dernière correspondait à une méthode de ligne de partage des eaux (voir section 2.2.3.2. Bien que la quantité de méthodes étudiée fût importante, les auteurs ont conclu sur la difficulté quant au choix de l'une d'entre elles. En effet, les résultats qu'elles offrent dépendent des paramètres de reconstruction des images, du filtre utilisé lors du filtrage *post*-reconstruction, ou de la valeur de SUV maximale dans la lésion.

Dans [Troost *et al.*, 2010a], les auteurs proposent d'utiliser deux méthodes de segmentation pour évaluer la réponse au traitement par radiothérapie sur des tumeurs ORL. La première est un seuillage fixe à 50 % et la seconde à un seuillage fonction de l'intensité mesurée dans le fond. Les résultats montrent que le seuillage à 50 % semble donner de meilleurs résultats en raison du faible contraste observé en cours de traitement. En outre, les auteurs évoquent la possibilité d'effectuer une escalade de dose à partir d'un sous-volume obtenu à partir d'un seuillage fixe à 80 % de l'intensité maximale.

Une étude menée par Han *et al.* [2010] a comparée six méthodes de seuillage fixe en imagerie TEP à la  $^{18}\text{FLT}$ . Parmi les six seuils, trois correspondaient à une valeur de SUV (1,3 ; 1,4 et 1,5), et trois autres étaient fonction du SUV maximum (20 %, 25 % et 30 %). Les faibles seuils de SUV choisis sont dus à la faible fixation du traceur comparée au  $^{18}\text{FDG}$  pour lequel les auteurs proposent d'utiliser un seuil SUV égal à 2,5. L'étude comparative rapporte que le seuil offrant la meilleure estimation de la taille des tumeurs sur les images TEP, comparée à leur taille mesurée sur l'examen anatomo-pathologique, est un seuil du SUV de 1,4. Dans

[Tian *et al.*, 2008; Xu *et al.*, 2011], les auteurs proposent également d'utiliser une valeur seuil de 1,4 sur des lésions pulmonaires. Ils montrent que cette valeur apporte une bonne sensibilité et spécificité, notamment lorsque les images TEP à la  $^{18}\text{FLT}$  sont combinées aux images TEP au  $^{18}\text{FDG}$ .

### 2.2.1.2.3 Images TEP au $^{18}\text{FMiso}$

La grande majorité des méthodes proposées dans la littérature pour la TEP au  $^{18}\text{FMiso}$  reposent sur un seuillage fonction de l'intensité des voxels dans le muscle ou de l'activité dans le sang. Dans [Rasey *et al.*, 1996; Koh *et al.*, 1995], un seuil de 1,4 par rapport à l'activité dans le sang est utilisé pour segmenter les régions hypoxiques sur des images de cancer du poumon, ORL, et de la prostate. Rasey *et al.* [1996] rapporte que 99 % des voxels non tumoraux sont inférieurs à ce seuil. Cependant Rajendran *et al.* [2003] proposent d'utiliser un seuil de 1,2. Dans [Nehmeh *et al.*, 2008], ce seuil est également repris par les auteurs, et rapportent que 95 % des voxels non tumoraux sont inférieurs à ce seuil. L'utilisation d'un seuil fonction de l'activité prélevée dans le sang lors de l'acquisition puis convertie en une valeur de SUV, donne des résultats intéressants permettant de segmenter les régions hypoxiques. Néanmoins, le choix du seuil doit encore être confirmé.

Cette même conclusion peut être faite concernant le seuillage fonction de l'intensité mesurée dans le muscle. Dans [Gagel *et al.*, 2004; Eschmann *et al.*, 2005; Yeh *et al.*, 1996], le seuil proposé par les auteurs varie entre 1,3 et 1,6 fois l'intensité dans le muscle. Enfin, une étude comparative de 22 méthodes de seuillage a été menée au sein de notre laboratoire [Thureau *et al.*, 2012]. Les seuils utilisés étaient des valeurs de SUV, fonction de l'intensité maximale mesurée dans la tumeur, ainsi que des rapports fonction de l'intensité maximale ou moyenne mesurée dans des organes sains tels que l'aorte ou le muscle. Les résultats montrent, chez cinq patients, que l'application d'un seuil fixe de SUV égale à 1,4 semble donner les meilleurs résultats.

## 2.2.2 Approches par croissance de régions

### 2.2.2.1 Principe

Les algorithmes de croissance de région reposent sur l'agglomération des voxels autour d'un germe en fonction d'un critère de similarité avec celui-ci. Comme nous le verrons dans la prochaine section dédiée à la segmentation d'images TEP, le critère le plus utilisé est un critère d'homogénéité d'intensité des voxels. Il consiste généralement à agréger les voxels supérieurs à un seuil donné. Bien que cette approche soit souvent proche du seuillage, elle a l'avantage de lier les voxels par leur connexité.

### 2.2.2.2 État de l'art

Plusieurs auteurs ont proposé d'utiliser des approches par croissance de région pour la segmentation des images TEP. Dans, [Krohn *et al.*, 2007], à partir d'un germe fourni par l'utilisateur, les auteurs proposent dans un premier temps de rechercher le voxel d'intensité maximale dans son voisinage, puis de faire croître un volume autour de ce maximum en incluant tous les voxels dont l'intensité est supérieur à 41% de celle du maximum. Cette technique de segmentation offre une erreur moyenne de 3,5% pour des sphères de volume supérieur à 5 mL.

Dans [Haiying *et al.*, 2006; Potesil *et al.*, 2007], la croissance de région est également utilisée pour la segmentation des lésions. Les auteurs proposent d'utiliser un seuil de 40% de l'intensité maximale relevée. L'originalité de la méthode vient de la détection automatique des maxima dans l'ensemble du volume TEP.

Les approches précédemment décrites sont équivalentes à des méthodes de seuillage. Dans [Green *et al.*, 2008], les auteurs partent du principe que les méthodes de seuillage basées sur l'intensité maximale du signal sont biaisées du fait que l'intensité maximale n'est pas une mesure statistiquement robuste. Ils proposent ainsi d'utiliser une méthode composée de deux étapes. Tout d'abord, à partir d'un volume, la moyenne des intensités des voxels est calculée. Lors de la première itération, cette moyenne correspond à l'intensité du germe. Ensuite, un pourcentage, fonction de cette moyenne, permet de déterminer une valeur seuil. Ces deux étapes sont répétées de manière itérative tant que le nombre de voxels à identifier n'atteint pas zéro. Les auteurs proposent d'appliquer deux fois la méthode. La première fois, pour déterminer une première région à partir d'un germe défini manuellement par l'utilisateur. La seconde fois, pour déterminer le volume final à partir du germe correspondant à l'intensité maximale dans la région précédemment trouvée. La méthode semble intéressante puisqu'elle n'est pas opérateur-dépendante et permet aux auteurs d'évaluer la réponse des tumeurs au traitement par chimiothérapie. Cependant, il aurait été pertinent d'évaluer sa robustesse et son efficacité en la comparant par exemple avec d'autres méthodes de la littérature.

## 2.2.3 Approches dérivatives

### 2.2.3.1 Principe

L'approche dérivative, en imagerie, consiste à calculer la dérivée du signal de l'image suivant ses différents axes. Cette méthode est souvent utilisée car elle est simple à mettre en oeuvre et donne une information pertinente sur les contours des régions. La dérivée est effectuée par

filtrage de l'image avec un filtre pouvant avoir deux ou trois dimensions selon l'image et les choix de l'utilisateur.

Les filtres couramment rencontrés sont les filtres de gradient (dérivée première) nommés Roberts [Roberts, 1963], Prewitt [Prewitt, 1970] et Sobel [Sobel, 1978]. À l'issue du filtrage, les fortes valeurs indiquent la présence d'une forte variation en intensité du signal, et donc la présence d'un contour. On rencontre aussi les filtres Laplacien (dérivée seconde) [Davis, 1975]. Les contours sont alors identifiés par annulation du laplacien. Ces deux types de filtrage peuvent détecter de faux contours (faux positifs) lorsque du bruit est présent dans l'image. Dans [Canny, 1986], l'auteur introduit le filtre de Canny. Basé sur l'information de type gradient, il permet de détecter les contours d'une image tout en minimisant la présence de faux positifs.

La ligne de partage des eaux, *watershed* en anglais [Beucher et Lantuejoul, 1979], considère une image comme un relief topographique. Elle simule la montée progressive du niveau d'eau afin de trouver les lignes de crête dans le signal. Pour arriver à ce résultat, les méthodes de ligne de partage des eaux tirent souvent parti du gradient de l'image, c'est pourquoi nous classons cette approche parmi les approches dérivatives.

### 2.2.3.2 État de l'art

Une méthode basée sur le calcul du gradient de l'image a été proposée dans [Shen *et al.*, 2007] puis comparée à une méthode de seuillage à 37% de l'intensité maximale. L'étude a porté sur la comparaison, sur des images de fantômes, de la robustesse des deux méthodes vis à vis de différents contrastes, de différentes tailles de sphères et différentes méthodes de reconstruction. Les résultats montrent que la méthode utilisant le gradient est plus robuste que la méthode par seuillage sur ce type d'images.

Les premiers auteurs à proposer l'utilisation de la ligne de partage des eaux pour la segmentation d'images TEP sont Riddell *et al.* [Riddell *et al.*, 1999]. Leur approche multi-résolution, travaillant sur l'image d'origine ainsi que sur une version floutée, a pour intérêt d'être robuste face au bruit important sur les images TEP. Notons cependant que l'étude ne porte pas sur la segmentation de volumes lésionnels précis. Plusieurs auteurs se sont penchés sur la comparaison de la méthode par ligne de partage des eaux, aux méthodes de seuillage. Dans [Tylski *et al.*, 2006], les deux méthodes donnent des résultats comparables. Cependant, les auteurs préfèrent les méthodes de ligne de partage des eaux, car elles ne nécessitent pas d'étape de calibration, mais uniquement d'une sélection à l'initialisation de germes à l'extérieur et à l'intérieur de la lésion afin d'identifier sa position. Dans [Geets *et al.*, 2007], une méthode originale de ligne de partage des eaux a été proposée et est comparée à la méthode de Daisne *et al.* [2003]. Les

auteurs critiquent la méthode de seuillage, et plus précisément la calibration effectuée sur des images aux contours nets qui engendre une sur-estimation des lésions dont les contours sont flous. La méthode proposée par les auteurs est composée de quatre étapes séquentielles. Tout d'abord, un filtrage bilatéral [Elad, 2002] est appliqué afin de réduire le bruit statistique dans l'image TEP tout en n'affectant pas les contours flous. Une déconvolution, en fonction de la PSF (Point Spread Function), supposée constante dans l'image, est ensuite appliquée de manière à réduire les transitions floues. Le bruit et le flou étant ainsi peu présents, l'algorithme de ligne de partage des eaux est ensuite appliqué. Enfin, un algorithme de *clustering* de type CAH (*Classification Ascendante Hiérarchique*) utilisant le critère de similarité de Ward [Jain *et al.*, 1999] est ensuite appliquée. Cette dernière étape permet de réduire la granularité du contour. Cette méthode, comparée à [Daisne *et al.*, 2003], semble moins sur-estimer les lésions sur des images provenant de patients. Dans [Roels *et al.*], les auteurs proposent d'utiliser cette méthode pour la segmentation des images TEP à la  $^{18}\text{FLT}$  et au  $^{18}\text{FMiso}$ . Cette méthode, n'étant pas basée sur un seuillage fonction de l'intensité maximale, ni d'un SUV, la rendrait indépendante du traceur.

Plus récemment, l'approche par croissance de région a été comparée à une approche utilisant un filtre gradient uniquement (filtre de Sobel), ainsi qu'à un seuillage dont le seuil dépend du contraste entre la lésion et le fond [Drever *et al.*, 2007]. De meilleurs résultats sont obtenus en utilisant la méthode de seuillage, le bruit et l'effet de volume partiel dégradant les contours.

#### 2.2.4 Modèle déformable

Une approche intéressante, utilisant un modèle déformable, est présentée dans [Wojak *et al.*, 2010a]. Une approche multimodale TEP/TDM est appliquée pour la segmentation de tumeurs pulmonaires. L'imagerie TDM seule permet difficilement la différentiation entre les tumeurs, les vaisseaux sanguins, ainsi que les tissus sains. Leur méthode, qu'ils appliquent sur la modalité TDM, tient compte d'un paramètre fonction du signal fourni par la modalité TEP. La modalité TEP permet alors de faire converger de manière plus efficace le contour vers la tumeur à segmenter. Bien qu'intéressante, notons que la méthode n'a pas été introduite dans le but de segmenter les lésions sur la modalité TEP seule, mais également et principalement sur l'imagerie par TDM.



## 2.2.5 Approches probabilistes

### 2.2.5.1 Principe

Les approches probabilistes ont pour objectif d'estimer les probabilités d'appartenance des observations aux classes, et ont pour intérêt de donner des mesures d'incertitude. Ces approches présentent l'avantage d'être fondées sur le formalisme régi par le théorème de Bayes. On nomme inférence bayésienne la démarche logique permettant de manipuler les probabilités. Soient deux variables aléatoires  $X$  et  $Y$  représentant respectivement un ensemble de classes discrètes et un ensemble d'observations à valeur dans  $\mathbb{R}^d$ , où  $d$  est la dimension de l'espace des caractéristiques. L'objectif est alors de déterminer les probabilités des classes conditionnellement aux observations. Ces probabilités sont déterminées grâce au théorème de Bayes que l'on approxime en :

$$P(X|Y) = \frac{P(X)P(Y|X)}{P(Y)} \approx P(X)P(Y|X) \quad (2.1)$$

où  $P(X)$  et  $P(Y|X)$  sont respectivement la probabilité *a priori* et la fonction de vraisemblance. La probabilité *a priori* ainsi que les paramètres de la fonction de vraisemblance, souvent gaussienne, sont dans la majeure partie des applications estimés grâce à l'algorithme *Expectation-Maximization* (EM) [Dempster *et al.*, 1977]. Cet algorithme est déterministe et peut malheureusement converger vers un optimum local. L'utilisation d'une version stochastique a été proposée pour éviter ce phénomène [Celeux et Diebolt, 1986].

Parmi les applications basées sur les probabilités, certaines utilisent le modèle markovien [Rabiner, 1990]. Il a pour principe d'estimer un événement futur à partir du présent. Les champs de Markov, en imagerie, ont pour principe de prendre en compte les dépendances spatiales entre les voxels dans le calcul des probabilités, permettant de lutter contre le bruit dans l'image [CHEN *et al.*, 2001].

### 2.2.5.2 État de l'art

Dans [Aristophanous *et al.*, 2007], les auteurs proposent de représenter les images TEP par un modèle Bayésien à base d'un mélange de gaussiennes. La méthode consiste à classer l'ensemble des voxels sélectionnés dans une région d'intérêt préalablement sélectionnée à la main suivant trois hypothèses correspondant au fond, à la transition et à l'hyper-fixation. Afin de réaliser cette classification, les auteurs proposent d'estimer la probabilité d'appartenance des voxels à chaque classe via l'algorithme de classification non supervisé Expectation Maximization, puis d'appliquer une règle de décision basée sur une maximisation des probabilités *a posteriori*. Un ensemble de dix classes est considéré : six correspondent au fond, une à la tran-

sition, et trois à l'hyper-fixation. La méthode est développée sur trois cas cliniques présentant des tumeurs pulmonaires et vérifiée sur quatre autres. L'avantage de la méthode est qu'elle semble plus fiable, plus reproductible et plus robuste que les méthodes basées sur le seuillage fixe à 40% et sur un seuillage adaptatif [Nestle *et al.*, 2005]. Cependant, il est important de noter que cette méthode nécessite l'intervention de l'utilisateur lors de la phase d'initialisation. Celui-ci doit spécifier la position des moyennes correspondant à la dernière classe du fond et à la transition floue. Cette intervention confère à la méthode une dépendance vis-à-vis de l'utilisateur. En outre, les résultats offerts par cette méthode pourraient sans doute être améliorés en intégrant la connaissance du contexte spatial.

Une approche originale est proposée dans [Montgomery *et al.*, 2007] pour la segmentation d'images PET au  $^{18}\text{F}$ FDG. Dans un premier temps, l'algorithme EM est appliqué afin de segmenter de manière grossière l'image TEP. À la différence de la méthode présentée précédemment, les auteurs proposent ici d'initialiser l'algorithme EM à l'aide de l'algorithme de *clustering k-means*, de déterminer le nombre optimal de classes de manière automatique en utilisant le *Bayesian Information Criterion (BIC)*, puis d'appliquer l'algorithme EM à plusieurs reprises pour finalement retenir de manière automatique la segmentation la plus satisfaisante. Cette procédure est effectuée afin d'éviter que l'algorithme converge vers un optimum local, ce qui peut être le cas car les auteurs appliquent leur méthode non pas sur un volume d'intérêt préalablement sélectionné de manière manuelle, mais sur l'image entière. Dans un second temps, les auteurs proposent d'appliquer à l'image initiale la transformée en ondelettes à trous [Starck *et al.*, 1998], puis de combiner le résultat de la transformée, à l'image segmentée par l'algorithme EM par l'intermédiaire d'un champ de Markov. L'objectif est d'affiner le résultat de la segmentation précédemment obtenu en tenant compte du voisinage grâce à la transformée en ondelette. Les résultats sur un fantôme anthropomorphe montrent une meilleure estimation du volume des sphères comparé à l'algorithme *k-means* seul et un champ de markov classique. Néanmoins, il aurait été intéressant de comparer la méthode avec les méthodes de la littérature dédiées à la segmentation des images TEP. Notons en outre que la méthode est algorithmiquement très complexe et induit donc des temps de calcul importants.

Dans [Hatt *et al.*, 2007, 2008], les auteurs proposent différentes méthodes de segmentation de volumes fonctionnels en imagerie TEP au  $^{18}\text{F}$ FDG. Leurs approches sont intéressantes car utilisent des mélanges de classes pour améliorer les segmentations basées sur des modèles statistiques. L'objectif est de créer une méthode robuste capable de s'affranchir des imperfections contenues dans les images en terme de bruit, de contraste, de forme et de fixation hétérogène des tumeurs. Hatt *et al.* critiquent en effet les méthodes courantes de segmentation d'images

TEP basées sur de simples seuillages qui ne permettent notamment pas de considérer le flou induit par la résolution spatiale, ainsi que le bruit. La première méthode introduite dans [Hatt *et al.*, 2007] propose de segmenter les volumes fonctionnels à l'aide des chaînes de Markov cachées en deux classes et deux transitions floues séparant les deux classes. La méthode permet ainsi de considérer chaque voxel comme appartenant soit à l'une des deux classes, soit à l'une des transitions floues. Afin de finalement décider uniquement en faveur d'une des deux classes, un voxel attribué à une transition floue est étiqueté à la classe la plus proche de la transition. Les auteurs montrent que leur méthode offre de meilleures performances quand elle tient compte des transitions floues que quand elle n'en tient pas compte. Afin d'atténuer le coût calculatoire, notons que les auteurs préfèrent utiliser une chaîne de Markov plutôt qu'un champ, où la chaîne suit la courbe d'Hilbert Peano 3D dans l'image [Kamata *et al.*, 1999]. Toute l'information spatiale 3D n'est ainsi pas considérée.

Dans [Hatt *et al.*, 2008], les auteurs modifient leur méthode en implémentant un modèle statistique utilisant encore une fois les mélanges de classes, mais en tenant compte, à présent, de toute l'information spatiale 3D. Cette dernière méthode, nommée FLAB pour *Fuzzy Locally Adaptive Bayesian* permet de modéliser chaque classe et chaque transition floue par une gaussienne. Plusieurs paramètres composent la méthode : les moyennes et variances relatives aux classes et aux transitions floues, ainsi que les probabilités *a priori* d'observation des classes dans le voisinage  $3 \times 3 \times 3$  de chaque voxel. L'estimation itérative de ces paramètres est réalisée grâce à l'algorithme SEM (*Stochastique Expectation Maximisation*), une version stochastique de l'algorithme EM qui permet d'éviter de faire converger les paramètres vers un minimum local. Finalement, la segmentation est effectuée par maximisation de la probabilité *a posteriori* des classes et des transitions floues pour chaque voxel. Une étude sur des images de différents contrastes provenant de fantômes montre que la méthode FLAB est plus performante que les méthodes à base de seuillages, et est également plus performante et plus rapide que la méthode à base de chaînes de Markov floues initialement proposée. Dans [Hatt *et al.*, 2010b] les auteurs proposent d'appliquer la méthode introduite dans [Hatt *et al.*, 2008] aux images TEP à la  $^{18}\text{FLT}$ . Bien que l'étude ne portât pas sur la pertinence de l'estimation des volumes cible, les auteurs évoquent la possibilité d'appliquer des méthodes bayésiennes ou floues sur des images obtenues à partir de traceurs autre que le  $^{18}\text{FDG}$ . Dans [David *et al.*, 2011], les auteurs modifient la méthode de manière à ce qu'elle puisse être appliquée sur des espaces à plus de 2 dimensions et plus de 2 classes. Ainsi, ils évoquent la possibilité de segmenter des images TEP multi-traceurs, où chaque traceur apporterait une nouvelle dimension au problème de segmentation. La méthode n'est cependant pas appliquée dans ce but, mais dans le cadre

de la segmentation d'images acquises avant et pendant radiothérapie afin d'évaluer la réponse au traitement.

Enfin, ces mêmes auteurs [Hatt *et al.*, 2010a] ont proposé d'étendre leur méthode de segmentation à trois classes où l'objectif est de tenir compte de l'hétérogénéité des tumeurs. Cette dernière approche a été évaluée sur des images simulées hétérogènes pour lesquelles la vérité terrain est disponible. La méthode d'obtention de ces images (simulation Monte Carlo) a la particularité de reproduire les phénomènes physiques des systèmes d'acquisition TEP, et offre des images davantage comparables aux données réelles par rapport aux fantômes. La méthode FLAB à trois classes [Hatt *et al.*, 2010a] est appliquée sur ces images simulées et comparée à la méthode FLAB à deux classes [Hatt *et al.*, 2008], à l'algorithme FCM, ainsi qu'à un seuillage adaptatif. Les résultats montrent tout d'abord que la méthode FLAB à deux classes donne des taux d'erreur moins importants que FCM et le seuillage adaptatif. En outre, la méthode FLAB à trois classes offre de meilleurs résultats que la méthode à deux classes.

Dans [Haase *et al.*, 2010], les auteurs proposent une méthode originale, reproduisant le mouvement de colonies de fourmis [Colorni *et al.*, 1991] dans les images, afin de s'adapter au faible contraste et à l'importante quantité de bruit pour segmenter les images TEP au  $^{18}\text{FMiso}$ . Leur méthode, tenant très largement compte des relations spatiales entre les voxels, consiste à simuler le mouvement des fourmis dans les images et leur reproduction en les attirant vers le signal de haute intensité et vers les forts gradients d'intensité. Leur méthode semble donner de bons résultats sur les images de fantômes présentant un faible contraste. Elle souffre néanmoins d'un manque de comparaison avec d'autres méthodes de la littérature pour la segmentation d'images TEP au  $^{18}\text{FMiso}$ . En outre, les auteurs rapportent qu'elle ne permet pas de tenir compte de l'effet de volume partiel.

## 2.2.6 Approche floue

### 2.2.6.1 Principe

L'approche floue s'appuie sur la théorie des ensembles flous [Zadeh, 1965]. À la différence de l'approche probabiliste, elle consiste non pas à estimer des probabilités, mais des degrés d'appartenance vis-à-vis de l'ensemble des classes considérées. L'intérêt n'est plus de donner une mesure d'incertitude sur l'appartenance d'une observation à une classe, mais d'imprécision. Cela signifie que l'on ne cherche pas à quelle classe une observation semble appartenir, mais avec quel degré il appartient à chacune des classes. La méthode automatique la plus utilisée dans la littérature pour estimer automatiquement les degrés d'appartenance est l'algorithme *Fuzzy*

*C-Means* (FCM) [Bezdek, 1981]. Cet algorithme est une variante de la méthode des k-means assignant aux observations un degré d'appartenance aux classes inversement proportionnel à la distance les séparant des centroïdes représentant ces classes.

### 2.2.6.2 État de l'art

Dans [Esnault *et al.*, 2007] les auteurs proposent une méthode utilisant les opérations morphologiques d'érosion et de dilatation sur un contour initialisé par l'intermédiaire d'un seuillage fixe. Deux nouveaux contours, un interne et un externe, sont ainsi obtenus. Le contour externe exclut les voxels en leur donnant un degré d'appartenance à la tumeur égal à 0. Le contour interne donne aux voxels qu'il inclut un degré d'appartenance à une tumeur de 1. Entre les deux contours, les auteurs proposent de donner aux voxels un degré d'appartenance à la tumeur entre 0 et 1, prédéterminé par une courbe sigmoïde et pondéré par le contraste local. Finalement, un seuillage par rapport à la valeur médiane (0,5) des degrés d'appartenance permet de définir le contour final. Bien que cette approche soit intéressante pour la détermination des degrés d'appartenance, les auteurs ont montré qu'elle s'avérait inefficace pour les lésions proches d'autres hyper-fixations. Bien que cette méthode utilise une approche floue pour la segmentation d'images, notons qu'elle reste très dépendante de l'initialisation qui consiste en un seuillage fixe.

L'algorithme de *clustering* Fuzzy C-Means (FCM) [Bezdek, 1981], une version floue de l'algorithme de *clustering* C-means, a notamment été appliqué à la segmentation d'images TEP du corps entier [Zaidi *et al.*, 2002]. Bien que l'objectif des auteurs ne soit pas de segmenter les lésions tumorales, mais de corriger les problèmes d'atténuation, les travaux montrent l'intérêt potentiel qu'offre l'algorithme FCM pour la segmentation en imagerie TEP. Ce dernier est appliqué à la segmentation des lésions tumorales dans [Zhu et Jiang, 2003]. Les résultats présentés sont cependant qualitatifs et ne permettent pas d'apprécier la performance de la méthode pour la détermination des volumes tumoraux. De meilleurs résultats pourraient d'ailleurs être obtenus en tenant compte de l'information spatiale.

Récemment, Zaidi *et al.* ont proposé de reprendre la méthode initialement introduite dans [Montgomery *et al.*, 2007] mais en utilisant non plus une approche probabiliste mais floue par l'intermédiaire de l'algorithme FCM à partir de trois signaux décrivant de manière différente la tumeur [Belhassen et Zaidi, 2010]. Le premier correspond à l'image initiale TEP, le deuxième correspond à l'image TEP filtrée avec un filtre anisotropique, le troisième correspond à l'image TEP transformée avec une ondelette à trous. L'intérêt du filtrage anisotropique est qu'il permet de lever les ambiguïtés dues au bruit au sein des régions sans impacter sur la qualité du signal

déjà faible à la transition entre les régions étant donné l'effet de volume partiel. La transformée en ondelettes a pour intérêt de détecter les hautes fréquences dans le signal, et permet ainsi d'améliorer la segmentation des régions présentant des hétérogénéités.

### 2.2.7 Approche par fusion

Dans [Dewalle-Vignion *et al.*, 2011], une approche floue faisant intervenir un processus de fusion est proposé. L'approche tire à la fois parti de l'information contenue dans le volume 3D et dans les plans 2D obtenus à partir d'images MIP (*Maximum of Intensity Projections*) du volume 3D. Trois images MIP sont considérées, chacune d'elles correspondant à la projection des intensités des voxels selon chacun des axes du repère cartésien 3D représentant le volume. L'idée est que les images MIP présentent un meilleur contraste que les données TEP initiales. Dans un premier temps, les auteurs proposent d'appliquer l'algorithme FCM à chacun des trois MIP. Il permet d'obtenir un degré vis à vis de l'appartenance des pixels de chaque MIP à la lésion tumorale. Dans un second temps, chacune de ces trois informations est pondérée à l'intensité des voxels du volume 3D, ce qui permet d'attribuer à chaque voxel trois degrés de possibilité relatif à son appartenance à la lésion tumorale. Par fusion de ces trois degrés de possibilité, la lésion tumorale peut alors être segmentée. La méthode proposée par les auteurs est originale puisqu'elle tient compte de l'information issue des MIP qui a l'avantage de présenter un meilleur contraste comparé à celui présent dans le volume 3D. Elle est également intéressante car elle porte sur la fusion d'informations permettant de renforcer la prise de décision dans la classification des voxels. Comparé aux méthodes par seuillage fixe, par seuillage adaptatif, et à l'algorithme FCM, leur méthode donne des taux d'erreur moins importants ou aussi bons que la méthode de seuillage adaptatif introduite dans [Nestle *et al.*, 2005], avec comme avantage cependant qu'elle ne requière pas d'étape de calibration. En outre, l'efficacité de la méthode vis à vis de l'hétérogénéité des tumeurs reste à évaluer.

### 2.2.8 Méthodes basées sur la texture

#### 2.2.8.1 Principe

Le contexte de classification est idéal lorsque la variance inter-classes est maximale et la variance intra-classe est minimale. En imagerie, la caractéristique de plus bas niveau est l'intensité des voxels. Elle est la plus souvent utilisée car propre à toute image. On trouve dans la littérature des applications tirant parti de caractéristiques de haut niveau telle que la texture obtenue par analyse des relations entre voxels voisins [Klein, 2008]. Cela s'avère très intéres-

sant lorsque l'image considérée présente une scène texturée telle qu'une scène naturelle avec une route, une forêt et le ciel. En revanche, leur utilisation peut se révéler inefficace lorsque la texture semble être la même au sein de chaque classe. Ces caractéristiques ne sont alors pas discriminantes.

### 2.2.8.2 État de l'art

Dans l'ensemble des approches mentionnées précédemment, les caractéristiques de plus bas niveau ont été utilisées pour la segmentation des images TEP, à savoir l'intensité des voxels. La majorité des méthodes que l'on rencontre dans la littérature tirant parti de caractéristiques de haut niveau pour la description des images TEP ont pour objectif d'évaluer la réponse au traitement. Cependant, on trouve dans la littérature une étude portant sur la segmentation des tumeurs à partir de caractéristiques de haut niveau [Yu *et al.*, 2009a]. Quatorze caractéristiques sont en tout considérées : cinq sont du premier ordre (moyenne, médiane, ...), trois sont issues des matrices de co-occurrence [Haralick *et al.*, 1973] mesurant des dépendances spatiales entre les voxels, trois sont des caractéristiques de haut niveau introduites dans [Amadasun, 1989] (contraste, finesse, ...), et trois sont des caractéristiques propres à la structure des régions telle que la symétrie. Le système de classification utilisé par les auteurs est un arbre de décision à deux classes (sain *vs.* pathologique) où la séparation des données, en chaque nœud de l'arbre, est effectuée via l'algorithme des k-plus proches voisins, deux méthodes de classification supervisée. Afin de construire ce classifieur supervisé, 76 régions pathologiques et 399 régions saines préalablement segmentées manuellement ont été utilisées. Pour évaluer les performances de cette méthode, une *cross-validation* par la méthode de *leave-one-out* a été effectuée. L'utilisation de la texture pour la description d'images TEP paraît intéressante. En effet, les résultats obtenus par les auteurs montrent une bonne discrimination entre les tissus sains et pathologiques. Les auteurs comparent, en outre, leur méthode à trois méthodes de seuillage : fixe à 50% de l'intensité maximale, fixe avec un seuil de SUV de 2,5, et fonction de l'intensité définie dans le fond. Leur méthode donne un résultat de segmentation plus proche de la vérité terrain délinéée par les radiothérapeutes. L'utilisation de la texture semble cependant limitée puisqu'elle ne peut pas être définie de manière fiable sur de très petites régions [Yu *et al.*, 2009b]. Dans [Galavis *et al.*, 2010], les auteurs rapportent que l'utilisation de caractéristiques de haut niveau, comme proposées dans [Yu *et al.*, 2009a], semblent moins bien adaptées à la tâche de segmentation que les caractéristiques de bas niveau. Ils rapportent en effet que la texture est dépendante des paramètres de reconstruction des images TEP.

## 2.3 Évaluation de sept méthodes de segmentation

Dans cette section, sept des méthodes précédemment décrites ont été étudiées afin d'évaluer leurs performances. Nous avons utilisé des images de fantôme TEP dont la vérité terrain est connue pour mener cette étude.

### 2.3.1 Matériels et méthodes

#### 2.3.1.1 Acquisition des données

Les données ont été acquises sur un fantôme de Jaszczak (Data Spectrum Corporation, Hillsborough, NC, USA). Il s'agit d'un fantôme cylindrique, dont le diamètre et la hauteur interne sont respectivement de 21,6 cm et 18,6 cm. Il contient un ensemble de neuf sphères (Figure 2.1) de volume compris entre 0,43 mL et 97,3 mL (0,43 ; 0,99 ; 2,08 ; 3,78 ; 11,6 ; 19,3 ; 27,9 ; 58,1 et 97,3 mL).

Lors de l'acquisition, initialement ( $t = 0$ ), les sphères étaient toutes remplies avec une concentration d'activité égale à 41,6 kBq/mL, tandis que le fond était rempli avec une concentration de 5,4 kBq/mL afin de se rapprocher des valeurs rencontrées en clinique (5,0 MBq/kg) lors d'exams TEP au  $^{18}\text{F}$ FDG. Ceci a permis de réaliser une première acquisition ( $t = 0$ ) avec un rapport de contraste entre les sphères et le fond ( $C_{S/F}$ ) égal à 7,7. Ensuite, de l'activité a successivement été ajoutée dans le fond du fantôme à  $t = 50, 100, 150, 200$  min afin de réaliser respectivement des acquisitions avec des  $C_{S/F} = 6,3 ; 4,9 ; 3,4$  et 2,0.



Figure 2.1 – Fantôme cylindrique de Jaszczak (Data Spectrum Corporation, Hillsborough, NC, USA) contenant 9 sphères.



Les acquisitions TEP ont été réalisées à l'aide du *Biograph Sensation 16 Hi-Res* et reconstruites sur une station de traitement *Navigator* (SIEMENS Medical Solution, Knoxville, TN, USA) en utilisant le même protocole que celui employé pour les examens corps entier en routine clinique.

Les données d'émission ont été obtenues en mode 3D avec un champ de vue (*Field-Of-View* : FOV) transaxial de 605 mm et axial de 162 mm générant 81 images d'épaisseur 2 mm par pas d'acquisition de durée 3 min. Les données ont été corrigées des coïncidences aléatoires et diffusées, de la décroissance radioactive, de l'uniformité et de l'atténuation. Les images ont été reconstruites avec l'algorithme OSEM pondérant ces deux derniers phénomènes (*Attenuation Normalisation Weighted OSEM* : ANW-OSEM). Les paramètres de reconstruction utilisés étaient de 4 itérations et 8 sous-ensembles, une matrice image de  $168 \times 168$  voxels de dimensions unitaires égales à  $4,06 \text{ mm} \times 4,06 \text{ mm} \times 2,0 \text{ mm}$  respectivement dans les directions radiale, tangentielle et axiale, ainsi que l'application d'un post-filtrage gaussien isotrope de FWHM = 5 mm. La résolution spatiale du *Biograph* est de 4,2 et 4,8 mm dans le plan transaxial respectivement à 1 cm et 10 cm du centre du FOV, tandis qu'elle vaut 4,7 et 5,7 mm dans le plan axial.

La plus petite des sphères, dont le volume fait 0,43 mL, n'était pas visible sur les deux plus faibles contrastes ( $C_{S/F} = \{2, 0 ; 3, 4\}$ ). La sphère de 0,99 mL n'était également pas visible avec le contraste 2. Au total, 43 sphères étaient visibles et ont permis d'évaluer les méthodes.

### 2.3.1.2 Méthodes de segmentation évaluées

Dans le cadre de notre problématique de segmentation d'images TEP au  $^{18}\text{FDG}$ , nous avons choisi d'implémenter et de comparer sept méthodes automatiques ou semi-automatiques. Parmi elles, cinq ont été spécifiquement proposées dans la littérature pour la segmentation des images TEP au  $^{18}\text{FDG}$ . La liste des méthodes proposées est donnée dans le Tableau 2.1. Les méthodes à base de gradient n'ont pas été sélectionnées, le bruit et l'effet de volume partiel en imagerie TEP entraînant une dégradation trop importante des contours.

La première méthode est un seuillage fixe à 40 % (S40) du maximum proposée par Erdi *et al.* [1997]. La seconde est un seuillage adaptatif (Sad) proposé par Vauclin *et al.* [2010] au sein de notre laboratoire, et inspiré du seuillage adaptatif introduit par Daisne *et al.* [2003]. Ces deux méthodes de seuillages ont été choisies car les seuillages fixes et adaptatifs, font partie des méthodes les plus référencées dans la littérature pour la segmentation des images TEP.

Deux méthodes automatiques ont également été comparées, à savoir l'algorithme *Expectation-Maximization* (EM) [Dempster *et al.*, 1977] et le *Fuzzy C-Means* (FCM) [Bezdek, 1981]. Ces

deux méthodes n'ont pas été introduites spécifiquement pour la segmentation des images TEP, mais sont fréquemment rencontrées dans la littérature dans de nombreux problèmes de classification. Notons que l'algorithme FCM a déjà été utilisé par Zaidi *et al.* [2002] pour la segmentation des images TEP et semble offrir de bons résultats. Pour ces deux méthodes, deux classes ont été considérées afin de séparer l'hyper-fixation du fond. Un modèle Gaussien a caractérisé les classes pour la méthode EM, et le coefficient d'imprécision pour le FCM a été fixé à 2.

La méthode de mélange de gaussiennes (*Gaussian Mixture Model* : GMM) introduite par Aristophanous *et al.* [2007], et présentée section 2.2.5.2, a en outre été étudiée. C'est une extension de l'algorithme EM, où dix classes sont considérées afin d'adapter la méthode aux images TEP : trois pour le fond, six pour la lésion tumorale, et une pour la transition floue. Cette méthode est semi-automatique puisque les centroïdes pour deux des classes sont initialisés manuellement.

Une extension de l'algorithme FCM, proposée par Belhassen et Zaidi [2010] et présentée section 2.2.6.2, a également été étudiée. Elle est nommée FCM-SW dû à l'utilisation du contexte Spatial (S) et d'une transformée en ondelettes à trous (W : *Wavelet*) [Starck *et al.*, 1998]. Cette méthode, plus complexe, semble intéressante car elle permet de tenir compte du bruit dans les images, ainsi que de l'hétérogénéité des hyper-fixations.

Enfin, la méthode nommée FLAB, introduite par Hatt *et al.* [2008] pour la segmentation des images TEP au  $^{18}\text{FDG}$  et présentée section 2.2.5.2, a été implémentée pour les bonnes performances qu'elle semble offrir. La version de la méthode que nous avons choisi de réimplémenter est celle composée de deux classes, la méthode à trois classes ayant été introduite dans le but de tenir compte d'hétérogénéités absentes sur le fantôme de Jaszczak qui nous sert d'évaluation.

Méthodes	Abréviations	Auteurs
Seuillage fixe à 40% du maximum	S40%	[Erdi <i>et al.</i> , 1997]
Seuillage adaptatif	Sad	[Vauclin <i>et al.</i> , 2010]
<i>Expectation-Maximization</i>	EM	[Dempster <i>et al.</i> , 1977]
<i>Fuzzy C-means</i>	FCM	[Bezdek, 1981]
<i>Gaussian Mixture Model</i>	GMM	[Aristophanous <i>et al.</i> , 2007]
<i>Fuzzy C-means-Spatial Wavelet</i>	FCM-SW	[Belhassen et Zaidi, 2010]
<i>Fuzzy Local Adaptatif Bayésien</i>	FLAB	[Hatt <i>et al.</i> , 2008]

Tableau 2.1 – Méthodes de segmentation d'images évaluées.

### 2.3.1.3 Implémentation des méthodes

L'ensemble de ces méthodes a été implémenté dans le langage de programmation *JAVA* et a été intégré sous forme de *plugin* au logiciel de traitement d'images *ImageJ*. Le *plugin*, muni

d'une interface, permet de fixer les paramètres des méthodes et de les exécuter à partir d'une région d'intérêt ou d'un point d'intérêt fixé par l'utilisateur via le logiciel *ImageJ*. Seule la méthode Sad n'a pas été développée par nos soins, car elle était déjà présente au sein de notre laboratoire.

Six de ces méthodes ont été comparées à partir d'une même ROI englobant la sphère à segmenter. Cette initialisation n'a pas été effectuée pour Sad car la méthode ne fonctionne pas à partir d'une région d'intérêt mais d'un germe défini par l'utilisateur.

### 2.3.2 Analyse des données

Dans le cadre de notre étude comparative, les indices volumiques ont été utilisés afin d'évaluer les méthodes. Sur les données fantômes, les volumes lésionnels sont connus et servent de référence. L'erreur relative ( $E_r$ ), donnée en pourcentage (%), entre le volume mesuré ( $Vol_m$ ) et le volume de référence ( $Vol_r$ ) a été calculée selon la relation :

$$E_r = 100 \cdot \frac{Vol_m - Vol_r}{Vol_m} \quad (2.2)$$

### 2.3.3 Résultats

Les résultats de l'analyse des pourcentages d'erreur relative commises par chacune des sept méthodes de segmentation étudiées sont présentés Tableau 2.2. Ayant regroupé les petites ( $Vol_r \leq 3,78$  mL) et les grandes sphères ( $Vol_r \geq 11,6$  mL), les pourcentages d'erreurs sont moyennés et l'écart type est donné pour chacun des contrastes. La séparation entre petites et grandes sphères a pour objectif d'analyser le comportement des méthodes vis-à-vis de la présence d'effet de volume partiel. Étant donné la FWHM des images variant entre 6 et 8 mm dans le champs de vue, les sphères inférieures à 3,78 mL, de diamètre inférieur à 20 mm, sont plus sujettes à l'effet de volume partiel que les autres sphères dont le diamètre est supérieur à 28 mm. Les résultats présentés Figure 2.2 correspondent aux pourcentages d'erreurs obtenus avec les méthodes Sad, FCM et FLAB pour chacune des sphères et chacun des contrastes.

#### 2.3.3.1 Seuillage fixe à 40% du maximum

L'utilisation du seuillage fixe est satisfaisante lorsque les structures sont volumineuses ( $Vol_r \geq 11,6$  mL) et à contraste élevé ( $C_{S/F} \geq 6,5$ ). Pour ces sphères, l'erreur relative moyenne est de 5,6 %. Au contraire, elle atteint rapidement ses limites pour les régions de petites tailles ou à contraste faible, avec une erreur relative moyenne à 40 %. Dans la littérature, le seuillage fixe de 40 % est souvent utilisé comme seuil de référence, bien qu'il ait clairement été montré

Méthodes	Contraste 2		Contraste 3,5		Contraste 5	
	petites sphères	grandes sphères	petites sphères	grandes sphères	petites sphères	grandes sphères
S40%	100±0	100±0	72,9±46,8	21,3±15	71,3±38,3	7,4±5
Sad	33,5±2,1	32,2±8,1	21,4±10,3	20,0±16	43,6±44,3	5,3±4,1
EM	25,9±1,5	8,7±5,9	28,4±28,1	24,4±6,9	88,0±12,5	41,3±9,8
FCM	64,6±50	24,8±3,9	49,4±44,2	16,4±2,7	41,1±42,1	12,7±2,3
GMM	10,4±8	12,8±5,7	16,1±23,7	8,2±3,4	79,5±30,5	17±8,7
FCM-SW	100±0	21,5±15,3	5,0±5,6	8,2±3,4	79,5±30,5	17±8,7
FLAB	28,0±10,4	32,75±8,8	52,1±44,1	19,3±5,1	33,8±44,5	14,3±3,6
Méthodes	Contraste 6,5		Contraste 8			
	petites sphères	grandes sphères	petites sphères	grandes sphères		
S40%	55,7±51,1	3,1±1,8	40,2±42,4	3,7±1,2		
Sad	51,9±44,8	3,0±3,4	50,8±40,3	3,7±1,7		
EM	100±0	55,3±16,3	100±0	49,8±9		
FCM	36,4±43,7	10,2±1,7	33,7±45	9,8±1,8		
GMM	84,0±27,9	27,8±9,4	75,5±34,9	22,5±7,7		
FCM-SW	84,0±27,9	27,8±9,4	75,5±34,9	22,5±7,7		
FLAB	35,2±43,24	11,8±3,4	30,7±46,6	10,8±2,7		

Tableau 2.2 – Valeurs moyennes des erreurs relatives de mesure de volume ( $\pm$  l'écart-type) du fantôme de Jaszczak, après segmentation par les huit méthodes évaluées, en fonction du contraste ; Petites sphères ( $Vol_r \leq 3,78$  mL) et grandes sphères ( $Vol_r \geq 11,6$  mL).

que cette méthode ne permet pas de prendre en compte toute la complexité de l'imagerie TEP, en particulier en cas de faible contraste ou de petit volume des lésions ( $\lesssim 4$  mL) [Vauclin *et al.*, 2010].

### 2.3.3.2 Seuillage adaptatif

Cette méthode présente un bon comportement pour les sphères de gros volume ( $\geq 11,6$  mL) avec une erreur moyenne sur la mesure du volume de 12,9 %. Pour les sphères de petit volume ( $\leq 3,78$  mL) l'erreur moyenne sur la mesure du volume est de 42,2 %. Ces mauvaises performances sont également bien mises en évidence Figure 2.2. Ce résultat se retrouve avec d'autres méthodes pour les petites sphères et/ou les bas contrastes. Le bon comportement global de la méthode est peut être dû à un biais méthodologique lié à la calibration de cette méthode avec le même fantôme. Les études sur d'autres bases de données permettraient de confirmer ou non ces bons résultats.

### 2.3.3.3 Expectation-Maximization

Cette méthode donne globalement de mauvaises performances de segmentation des hyperfixations. Les erreurs sur la mesure du volume restent toujours supérieures à 41,3% quelle que

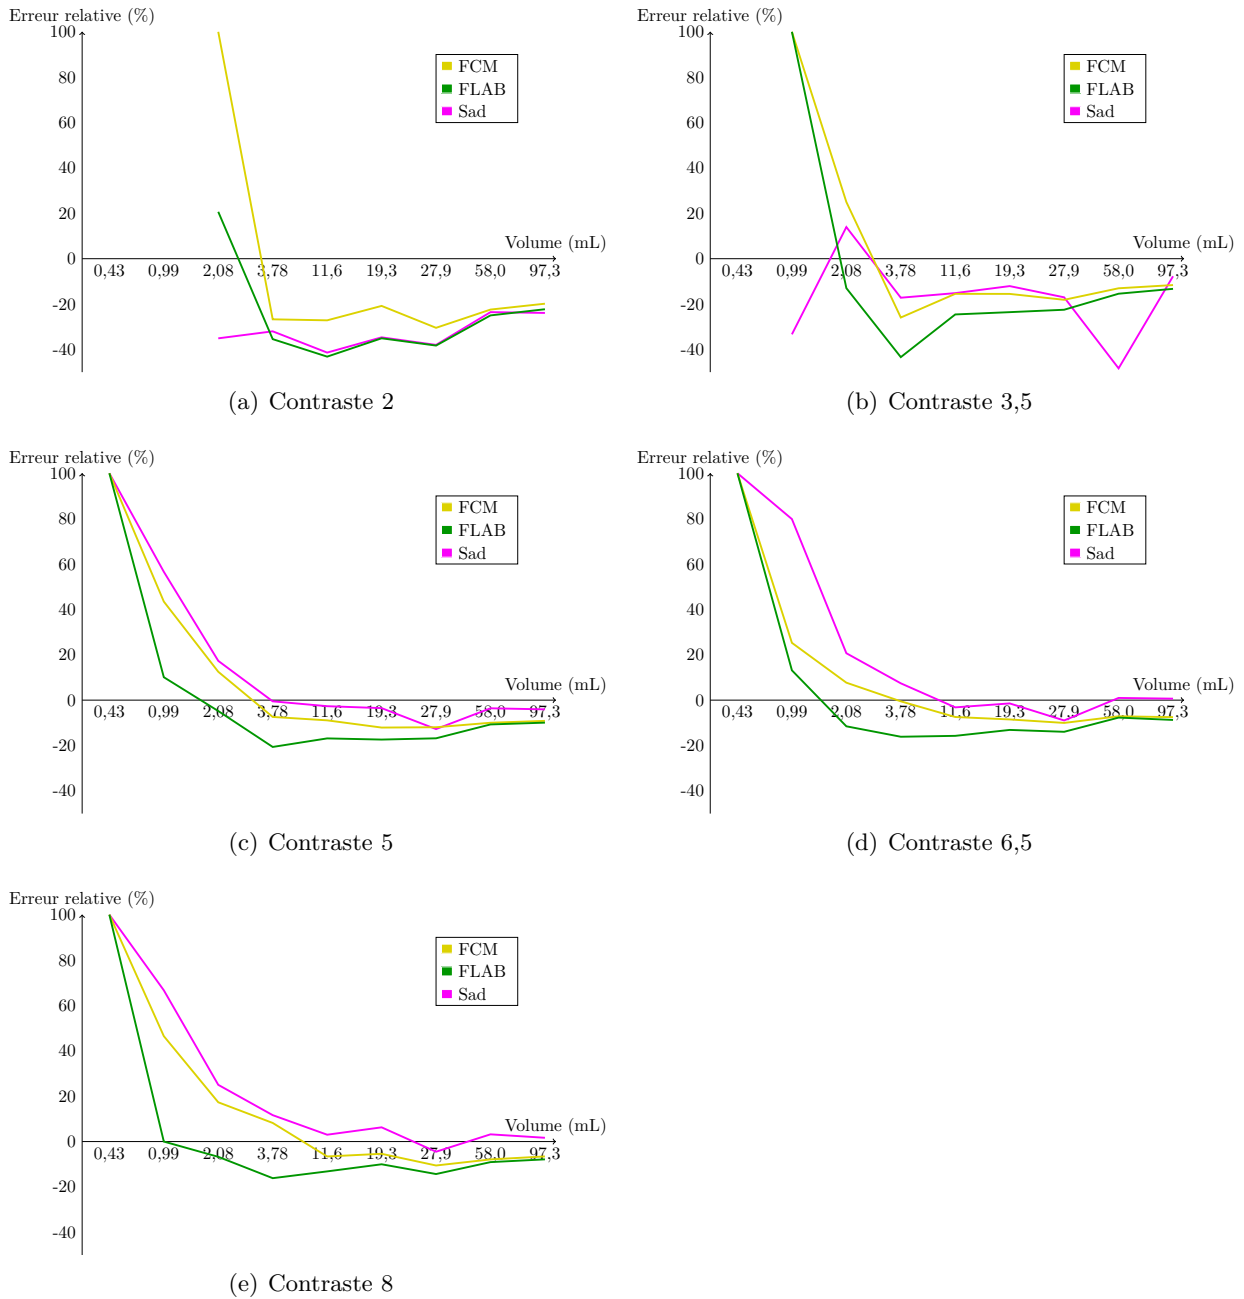


Figure 2.2 – Pourcentages d'erreurs relatives sur la mesure du volume pour les différentes sphères du fantôme de Jaszczak et les cinq contrastes avec les méthodes de segmentation Sad, FCM et FLAB.

soit la taille des sphères et pour les contrastes supérieurs à 5. Ceci est dû à la non-homogénéité des hyper-fixations qui induit un trop fort écart type, entraînant la sur-estimation du volume. En outre, cette méthode qui ne tient pas compte du voisinage, ne permet pas une segmentation correcte des hyper-fixations.

#### 2.3.3.4 Fuzzy C-means

Cette méthode donne de bons résultats quel que soit le contraste pour les sphères de volume supérieur à 3,78 mL. L'erreur moyenne sur la mesure du volume pour l'ensemble des contrastes est de 13%. La stabilité des mesures de cette méthode dans l'analyse sur fantôme de Jaszczak est intéressante dans le cadre de notre étude comparative. Comme pour la méthode Sad, les performances de la méthode se dégradent pour les petites sphères (Figure 2.2)

#### 2.3.3.5 Gaussian Mixture Model

Cette méthodes donne des performances médiocres pour les contrastes élevés avec une erreur sur la mesure du volume de 47 % en moyenne. Par ailleurs, lors de la phase d'initialisation, la méthode dépend de l'opérateur. Aristophanous *et al.* [2007] décrivent la procédure d'initialisation, mais cela ne nous a pas permis de réaliser des segmentations reproductibles. Cette contrainte réduit considérablement les performances de cette méthode.

#### 2.3.3.6 Fuzzy C-means-Spatial Wavelet

La première constatation est la relative faiblesse de cette méthode pour l'ensemble des mesures. En effet, la segmentation a tendance à perdre en stabilité pour les sphères de petit volume en particulier pour la sphère 4, du fait de sa position périphérique dans le fantôme, avec une erreur sur la mesure du volume de 69 % en moyenne pour les petits volumes ( $\leq 3,78$  mL) et de 20 % pour les sphères de gros volume ( $\geq 11,6$  mL). Bien que Belhassen et Zaidi [2010] aient cherché à améliorer la méthodes du FCM en l'associant à une transformée en ondelettes afin de prendre en compte les hétérogénéités, le résultat des mesures est peu convainquant dans le cadre de notre expérimentation. Ceci pourrait provenir du choix des auteurs à proposer une méthode entièrement automatique. En effet, le nombre de *clusters* est déterminé automatiquement, mais le nombre de cluster représentant la tumeur est constant (les deux plus grands *clusters*). Ce choix peut se révéler être un avantage pour la segmentation de lésions hétérogènes, mais un désavantage pour les lésions homogènes. Pour notre étude, le nombre de *clusters* déterminé a varié entre trois et cinq, en fonction du contraste, de la position et de la taille des sphères, ce

qui a provoqué de mauvaises estimations des volumes lorsque ce nombre était trop faible ou trop important.

### 2.3.3.7 Fuzzy Local Adaptatif Bayésien

Cette méthode tend à sous-estimer la mesure des volumes avec une erreur relative variant de  $-51\%$  jusqu'à  $-9,6\%$ . On constate un bon comportement général de la méthode, en particulier pour les sphères de petit volume, là où les autres méthodes échouent généralement (Figure 2.2). L'erreur moyenne sur les petits volumes ( $\leq 3,78$  mL) est de  $36\%$  pour FLAB contre des valeurs proches de  $100\%$  d'erreur pour les autres méthodes.

### 2.3.3.8 Discussion

Nous avons effectué une évaluation de sept méthodes de segmentation proposées dans la littérature sur un fantôme de Jaszczak composé de sphères de différentes tailles et plusieurs contrastes. L'activité contenue dans les sphères et le fond est homogène, ce qui est peu représentatif des lésions réelles observées, qui sont souvent hétérogènes. Le fantôme est néanmoins bien approprié pour une évaluation préliminaire des méthodes de la littérature et permet de comparer les volumes segmentés avec une vérité terrain fiable.

Parmi les sept méthodes, cinq ont été spécifiquement proposées dans la littérature pour la segmentation des images TEP au  $^{18}\text{FDG}$ , les deux autres étant souvent utilisées dans le cadre de la segmentation d'image. Étant donnée l'importante quantité de méthodes proposées dans la littérature, toutes n'ont pas pu être évaluées. Nous avons choisi deux méthodes de seuillage car cette approche est la plus largement décrite et utilisée dans la littérature [Zaidi et El Naqa, 2010]. Parmi elles, seule la méthode de seuillage adaptatif donne des résultats intéressants. De plus, nous nous sommes plus particulièrement intéressés aux méthodes faisant appel à la reconnaissance de formes selon des approches probabilistes [Dempster *et al.*, 1977; Aristophanous *et al.*, 2007; Hatt *et al.*, 2008] et floues [Bezdek, 1981; Belhassen et Zaidi, 2010]. Pour ces deux approches, nous avons dans un premier temps souhaité évaluer les performances des algorithmes classiquement proposés à visée de segmentation : l'algorithme EM pour l'approche probabiliste et FCM pour l'approche floue. Les performances de ces deux algorithmes montrent l'intérêt des méthodes de segmentation par reconnaissance de formes. Cependant, l'algorithme EM n'a pas permis de donner des segmentations satisfaisantes en raison des imperfections présentes dans les images TEP (bruit, effet de volume partiel). L'algorithme FCM donne en revanche des performances bien meilleures. Dans les améliorations de ces algorithmes proposées dans la littérature, trois algorithmes ont été développés et évalués (GMM, FCM-SW et FLAB). Parmi

eux, seuls FLAB a donné des résultats satisfaisants. Il faut noter que d'autres algorithmes basés sur la classification de voxels ont été proposés dans la littérature. Bien qu'ils semblent présenter des résultats intéressants, ils n'ont pas été retenus dans le cadre de ce travail en raison de leur complexité ou par manque d'information dans l'article originel.

Les méthodes S40%, EM, GMM et FCM-SW n'ont pas été retenues dans la suite de notre étude comparative de par leurs résultats assez médiocres. Des quatre méthodes, seule FCM-SW tient compte du voisinage, S40% n'est performante que sur des lésions volumineuses à haut contraste, EM surestime systématiquement les volumes segmentés et GMM présente un biais de reproductibilité, étant dépendante de l'opérateur. Notons que les faibles performances obtenues avec les méthodes GMM et FCM-SW sont certainement dues au fait qu'elles aient été proposées afin de tenir compte en partie des hétérogénéités dans les tumeurs, ce que l'on ne retrouve pas sur le fantôme de Jaszczak. Il est cependant regrettable qu'elles n'offrent pas de résultats satisfaisants sur les images présentant une hyper-fixation homogène.

Cette expérimentation à l'aide du fantôme de Jaszczak nous a donc permis de retenir les trois méthodes suivantes : Sad, FCM et FLAB. Il convient cependant de signaler que ces trois méthodes ont été évaluées dans des conditions particulières de lésions homogènes, avec une statistique de comptage favorable et un contraste supérieur ou égal à deux. Ces caractéristiques correspondent à des lésions homogènes au TEP  $^{18}\text{FDG}$  ou à la  $^{18}\text{FLT}$ , mais des conditions dégradées sont généralement présentes sur les images TEP au  $^{18}\text{FMiso}$ . La suite de nos travaux, portant en partie sur le développement d'une méthode de segmentation d'images TEP, sera évaluée par comparaison avec ces trois méthodes offrant de bonnes performance pour la segmentation des images TEP. Notre objectif sera également d'évaluer ces méthodes sur des images présentant une importante quantité de bruit telles que les images issues du traceur  $^{18}\text{FMiso}$ .

## 2.4 Conclusion

L'étude des différentes méthodes de segmentation, en début de chapitre, a, dans un premier temps, permis de présenter un aperçu des différentes méthodes de la littérature et leur capacité à tenir compte des imperfections contenues dans les images. Dans un second temps, les différentes méthodes de segmentation appliquées aux images TEP proposées dans la littérature, pour les traceurs  $^{18}\text{FDG}$ ,  $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$ , ont été présentées. La majeure partie des méthodes sont basées sur le seuillage, mais au vu des difficultés que l'on rencontre lors de la segmentation de



ces images, de plus en plus d'auteurs s'orientent vers les méthodes basées sur la reconnaissance de formes régies par la théorie des probabilités et des ensembles flous.

Dans la dernière section de ce chapitre, l'évaluation de sept des méthodes introduites pour la segmentation des images TEP au  $^{18}\text{FDG}$  a été présentée. Trois d'entre elles ont été retenues pour leurs bonnes performances par rapport aux quatre autres évaluées. La première est un seuillage adaptatif (Sad) [Vauclin *et al.*, 2010], la deuxième est l'algorithme de *clustering* classique FCM [Bezdek, 1981], et la dernière est la méthode FLAB [Hatt *et al.*, 2008].

Les méthodes basées sur la classification des voxels, selon un processus de reconnaissance de formes, semblent intéressantes. Certains auteurs ont investigué des pistes d'amélioration des algorithmes classiques tels que EM et FCM. Il nous semble que certaines pourraient être approfondies et d'autres investiguées. Trois voies nous paraissent plus particulièrement intéressantes. Tout d'abord, un effet de volume partiel et un bruit important montrent qu'une attention toute particulière doit être accordée à ces imperfections et que la méthode de segmentation proposée doit chercher à prendre en compte ces deux phénomènes. D'autre part, la méthode de segmentation proposée par Dewalle-Vignion *et al.* [2011] réalisant une fusion d'information sur des MIP paraît très intéressante car elle permet de segmenter des images de faible contraste sujettes au bruit et à l'effet de volume partiel. Enfin, des méthodes proposées dans la littérature pour la segmentation des hyper-fixations en imagerie TEP au  $^{18}\text{FDG}$  se sont appuyées sur des approches probabilistes ou relevant de la logique floue pour tenir compte des imperfections. À notre connaissance, les approches basées sur la théorie des fonctions de croyance n'ont pas été explorées alors qu'elles offrent un cadre plus large et mieux adapté dans la gestion des imperfections que la théorie des probabilités et la logique floue.

Lors du prochain chapitre, nous présenterons l'état de l'art des méthodes de fusion en imagerie médicale, avec en particulier une étude des différentes imperfections étudiées dans les problèmes de fusion basées sur les probabilités, les possibilités ou les croyances. Dans le chapitre 4, les bases théoriques des fonctions de croyance seront plus particulièrement étudiées ainsi que leur aptitude à modéliser explicitement les incertitudes et les imprécisions que l'on trouve en grande quantité dans nos images.

# Chapitre 3

## État de l'art de la fusion d'information en imagerie médicale

### Sommaire

---

<b>3.1</b>	<b>Introduction</b>	<b>73</b>
<b>3.2</b>	<b>Imperfections en imagerie</b>	<b>76</b>
3.2.1	Imperfections d'une source d'information	77
3.2.2	Liens entre plusieurs sources d'information	79
<b>3.3</b>	<b>État de l'art des méthodes de fusion en imagerie médicale</b>	<b>81</b>
3.3.1	Fusion par le vote	81
3.3.2	Fusion par approche probabiliste	82
3.3.3	Fusion par approche possibiliste	83
3.3.4	Fusion par fonctions de croyance	87
<b>3.4</b>	<b>Conclusion</b>	<b>90</b>

---

### 3.1 Introduction

Les systèmes automatiques de reconnaissance de formes sont souvent composés de trois étapes, à savoir, l'extraction de caractéristiques, l'apprentissage, et la prise de décision. L'apprentissage et la prise de décision sont réalisés par l'intermédiaire d'un classifieur, supervisé ou non, qui permet de décider à quelle classe appartient la source d'information.

La fusion d'information est apparue afin de gérer des données multi-sources. Ces données peuvent être nombreuses et issues de sources hétérogènes. En imagerie médicale notamment, comme nous l'avons vu dans le chapitre 1, il y a autant de sources d'information qu'il y a de modalité d'imagerie, et de radiotraceurs en imagerie TEP. En outre, chaque voxel d'une image est une source d'information. Étant donnée la dépendance spatiale qu'il y a entre les voxels voisins, il peut être considéré qu'il y a autant de sources d'information qui interviennent dans le choix d'une classe pour un voxel qu'il y a de voxels dans son voisinage. Le fait d'être en

présence d'images multi-traceurs tri-dimensionnelles nous amène à nous intéresser à la fusion des informations. D'après Bloch *et al.* [2003], la fusion d'information consiste à combiner des informations issues de plusieurs sources afin d'améliorer la prise de décision. L'idée est que de multiples sources d'information permettent, ensemble, d'améliorer la connaissance du monde observé. L'objectif est alors de fusionner les sources tout en tenant compte des différentes imperfections dont elles sont entachées. Pour ce faire, plusieurs méthodes de fusions sont proposées, et ce à de multiples niveaux. Les principales méthodes de fusion reposent sur le vote, les approches bayésiennes, les approches floues, ainsi que sur les approches basées sur la théorie des fonctions de croyance.

Comme l'illustre la Figure 3.1, trois niveaux de fusion existent [Dasarathy, 1997]. Ces niveaux sont les données, les caractéristiques, ainsi que les décisions. La fusion au niveau des données, dite de bas niveau, correspond à la fusion des informations directement issues du capteur. En imagerie, ce type d'information se rapporte à la valeur des voxels [Zhang *et al.*, 2011; David *et al.*, 2011]. Au niveau des caractéristiques, la fusion est dite de niveau intermédiaire et correspond à la fusion des caractéristiques extraites des données qui, en imagerie, peuvent correspondre à des informations de type texture [Cobzas *et al.*, 2007]. Enfin, la fusion de haut niveau, correspondant à la fusion des décisions, est relative à la fusion d'information correspondant à la formulation d'hypothèses issues d'un expert ou d'un système. La fusion à laquelle nous nous intéressons tout particulièrement, dans ce chapitre, est la fusion dite de haut niveau.

Les imperfections propres aux sources d'information sont souvent étudiées dans les systèmes de fusion. Comme nous l'avons vu lors des deux premiers chapitres, les images TEP sont entachées d'une importante quantité d'imperfections impactant significativement la qualité des images reconstruites. Comme indiqué au paragraphe 1.1.5.2.3, on peut distinguer le bruit et l'effet de volume partiel. Ces deux phénomènes ont pour origines la nature statistique du phénomène observé et la faible résolution spatiale du système d'acquisition. D'origine différente, il peut s'avérer pertinent de considérer séparément ces deux imperfections. Dans notre étude des méthodes de fusion d'images médicales, notre objectif sera non seulement d'étudier les différents procédés de fusion, mais également de se concentrer sur ceux permettant de tenir compte de façon différenciée ces deux types d'imperfection.

Après l'étude des différentes imperfections que l'on rencontre en imagerie, nous présenterons les principes des différentes méthodes de fusion d'information. Pour finir, nous présenterons un état de l'art des méthodes de fusion en imagerie médicale.

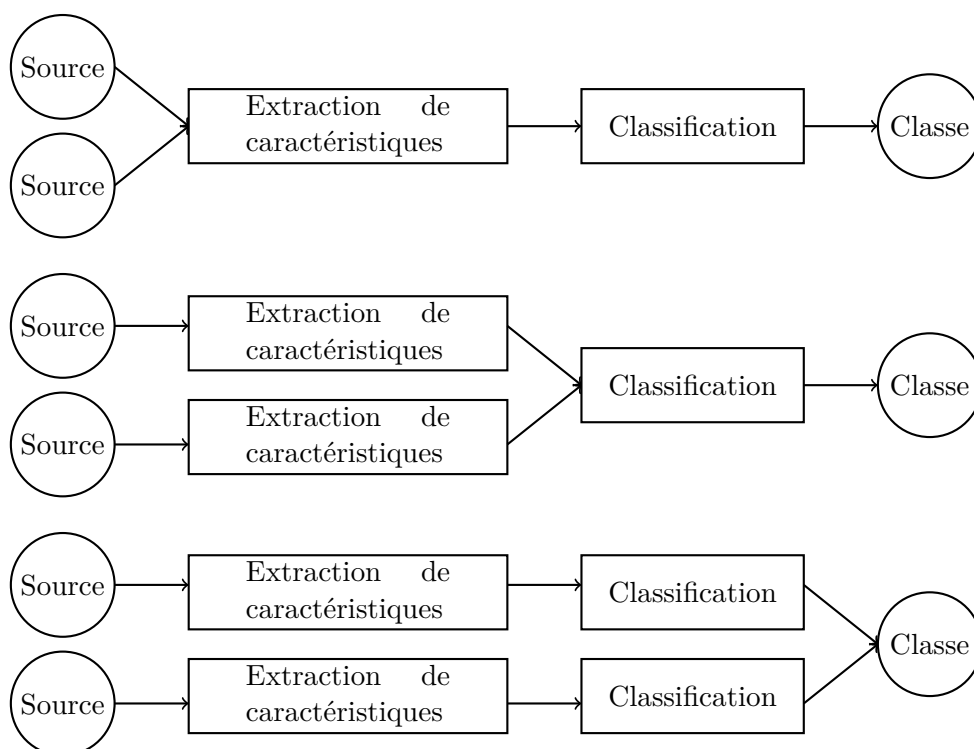


Figure 3.1 – Présentation des différents niveaux de fusion selon [Dasarathy, 1997]. La fusion des sources d'information issues du capteur est dite de bas niveau. La fusion des caractéristiques décrivant l'information est dite de niveau intermédiaire. La fusion, en sortie des classifieurs, est dite de haut niveau.

## 3.2 Imperfections en imagerie

La fusion d'information permet de lever les imperfections propres aux différentes sources. Une nouvelle source d'information peut être vue comme une information supplémentaire [Bloch *et al.*, 2003] et la fusion de cette dernière avec les sources déjà disponibles permet d'enrichir la connaissance que l'on a. Lorsque cette nouvelle information est entachée d'imperfections, dues à un défaut propre au capteur par exemple, la fusion peut engendrer une dégradation de l'information. La bonne modélisation des imperfections est essentielle pour éviter ce phénomène. Nous pouvons soit chercher à les supprimer, soit les tolérer, soit les modéliser. C'est cette dernière solution qui est souvent retenue dans les systèmes de fusion d'information. L'intérêt majeur de la fusion est alors de tirer parti des multiples sources d'information afin de réduire les imperfections modélisées, à condition que la connaissance apportée par l'ensemble des sources le permette.

En fusion d'information, on qualifie les sources par leur indépendance et leur fiabilité. L'indépendance est une hypothèse souvent faite qui, comme nous le verrons dans la prochaine section, peut être nécessaire selon le formalisme choisi. On rencontre deux types d'indépendance : l'indépendance statistique et cognitive. L'indépendance statistique vérifie la relation suivante :

$$P(S_i \cap S_j) = P(S_i) \cdot P(S_j), \quad (3.1)$$

où  $S_i$  et  $S_j$  sont deux sources d'information, et  $P(S_i)$  et  $P(S_j)$  leur probabilité d'observation. Cette indépendance, bien que rarement vérifiée, est souvent supposée dans les applications. L'indépendance cognitive est moins restrictive. Elle est vérifiée lorsque chaque source n'apporte aucune information sur les autres sources. Prenons pour exemple deux experts du même domaine. Ils sont indépendant cognitivement s'ils apportent un jugement sans se consulter. Ils ne sont statistiquement pas indépendants du fait qu'il possèdent le même savoir.

La fiabilité d'une source d'information peut correspondre soit à la fiabilité de la source à donner une information sûre, soit à la fiabilité de la source à donner une information [Martin, 2005]. Ces deux types de fiabilité sont liés à deux notions : l'incertitude et l'incomplétude. La prise en compte de la fiabilité des sources d'information est très importante dans un processus de fusion. Une source non fiable en contradiction avec les autres sources, qui elles sont fiables, aura une conséquence négative sur le résultat de la fusion.




Figure 3.2 – Image TEP au  $^{18}\text{F}$ FDG témoignant de l'importante quantité du bruit observée lorsque la concentration du radiotracteur est faible et que le temps d'acquisition est court. La Figure (b) présente la sous-région sélectionnée dans (a) et donne l'intensité de huit voxels.

### 3.2.1 Imperfections d'une source d'information

Les imperfections se définissent principalement en termes d'incertitude et d'imprécision. À ces deux définitions peuvent être ajoutées l'ambiguïté et l'incomplétude.

#### Incertainité

L'incertitude relate de la justesse d'une source d'information, ou de son degré de conformité, par rapport à la réalité. Elle peut aussi correspondre à la confiance qu'on attribue à la source d'information. L'incertitude correspond ainsi à une connaissance partielle de la réalité.

En imagerie, elle peut avoir pour origine le bruit en raison des nombreux phénomènes physiques parasites présents lors de l'acquisition. Dans la Figure 3.2, nous présentons une image de fantôme en TEP présentant une faible concentration en  $^{18}\text{F}$ FDG et un court temps d'acquisition. Il résulte qu'une importante quantité de bruit est présente. Comme l'illustre la Figure 3.2(b), une différence significative en intensité est constatée entre les voxels d'une même région alors qu'ils devraient en réalité tous posséder la même valeur. Ce phénomène témoigne de la présence d'incertitude pouvant être quantifiée pour chaque voxel comme l'écart entre la valeur mesurée et la vraie valeur qui devrait être observée.

#### Imprecision

L'imprécision est propre au contenu de l'information et correspond à un défaut quantitatif de connaissance. Cette imperfection ne doit pas être confondue avec l'incertitude, précédemment mentionnée, correspondant à un défaut qualitatif de connaissance.

En imagerie, elle peut correspondre à l'incapacité d'un système à définir de manière précise les contours d'un objet dû à un manque de précision du système d'acquisition. Nous illustrons ce phénomène à la Figure 3.3 pour une image TDM. Sur la région sélectionnée à la transition




Figure 3.3 – Image TDM témoignant de la présence d'effet de volume partiel à la transition entre les régions. La Figure (b) présente la sous-région sélectionnée dans (a) et donne l'intensité de six voxels en unité *Hounsfield* (UH).

entre le tissu mou et le poumon, malgré la relativement bonne résolution spatiale en TDM, nous pouvons observer une transition floue. Elle a pour origine l'effet de volume partiel, correspondant à un mélange entre plusieurs régions pour un voxel, et engendre de l'imprécision. En effet, le manque de connaissance ne nous permet pas de savoir si les voxels à la transition entre les régions appartiennent au tissu mou ou au poumon. Notons qu'en TEP, l'imprécision est beaucoup plus importante qu'en TDM car la résolution spatiale des images est plus faible (voir section 1.1.5.2.3).

### Ambiguïté

L'ambiguïté correspond à une information qui conduit à des interprétations différentes. L'ambiguïté peut être propre à une source d'information, mais peut également provenir d'imperfections telles que l'incertitude ou l'imprécision. Elle peut également venir d'un conflit entre plusieurs sources d'information comme nous le verrons ultérieurement.

En imagerie, la présence de bruit et d'effet de volume partiel peuvent conduire à des confusions dans la classification des voxels, et donc à la présence de données ambiguës. L'ambiguïté peut également provenir d'une source d'information. Comme nous l'avons vu section 1.1.5.1.2, en imagerie TDM, la connaissance de l'intensité des voxels seule ne permet pas de séparer les différents tissus mous. Un voxel dont l'intensité vaut  $35 \text{ UH}$  conduit à des interprétations différentes. Il peut par exemple correspondre au pancréas dont l'intensité des voxels varie entre 30 et 50  $\text{UH}$ , ou bien correspondre aux reins dont l'intensité des voxels varie entre 20 et 40  $\text{UH}$ .

### Incomplétude

L'incomplétude correspond au manque d'information apporté par la source, et peut engendrer la présence d'incertitude et d'imprécision. Elle peut se mesurer comme l'écart entre ce que




Figure 3.4 – Image TDM présentant un artéfact en étoile.

fournit la source d'information, et ce qu'elle devrait fournir. En cas d'incomplétude, la fiabilité de la source est faible.

En imagerie, l'incomplétude pourra être observée si le protocole d'acquisition des données ne se déroule pas normalement (panne partielle du système d'acquisition, défaut de positionnement de l'appareil, ...). En imagerie médicale, si ce type d'événement intervient, l'examen est reporté. Elle peut également être observée en présence d'artéfacts, correspondant à des données parasites. Un artéfact en étoile est présenté Figure 3.4. Il est causé par la présence d'un corps métallique. Ce type d'artéfact intervient lors de la reconstruction FBP (voir section 1.1.4.1) lorsqu'il existe des variations très importantes d'atténuation des photons localement. Il résulte que la valeur des voxels autour de cet artéfact ne possèdent pas la valeur qui devrait en réalité être observée avec la modalité TDM. L'information est alors entachée d'incomplétude, et n'est pas fiable.

### 3.2.2 Liens entre plusieurs sources d'information

Les imperfections sont propres à chaque source d'information. Dès lors que plusieurs sources d'information sont disponibles et interagissent entre elles, nous pouvons observer différentes particularités les liant, à savoir la redondance, la complémentarité et le conflit.

#### **Redondance**

Des sources d'information sont redondantes si elles apportent la même information. La fusion de sources redondante est intéressante car elle permet de confirmer ce que l'on a observé. Comme nous le verrons dans la prochaine section, la méthode de fusion par le vote exploite cette particularité. Le vote consiste en effet à choisir la classe possédant le plus d'occurrences.






Figure 3.5 – Deux images IRM complémentaires issues de [Bloch, 2008].

### Complémentarité

Des sources d'information sont complémentaires si l'information qu'elles apportent est de nature différente. La complémentarité est particulièrement intéressante car elle donne tout son sens à la fusion. La fusion de sources complémentaires peut notamment permettre de lever certaines ambiguïtés.

Dans [Bloch, 2008] deux images IRM double-echo du cerveau, d'un patient présentant une pathologie nommée adrénoleukodystrophie, sont fusionnées. Elles sont présentées Figure 3.5. La première image, Figure 3.5(a), permet de bien distinguer les ventricules au centre de l'image et le cerveau, mais ne permet pas de voir où se situe la zone pathologique. La seconde image, Figure 3.5(b), offre une bonne discrimination entre la zone pathologique en haut du cerveau et la zone saine, mais ne permet pas de bien distinguer les ventricules. Les images sont donc complémentaires.

### Conflit

Des sources d'information sont conflictuelles si elles sont contradictoires. Le conflit correspond à l'observation de phénomènes différents. Ces phénomènes peuvent être causés par la présence de sources non fiables (présence d'un artefact dans l'image) ou la mauvaise définition de l'ensemble des classes retenues. Le conflit permet alors d'observer une ambiguïté que l'on ne pouvait pas observer sur chaque source d'information prise individuellement.

En imagerie, à la transition entre les régions, les voxels voisins sont conflictuels puisqu'ils apportent des informations contradictoires. Dans [Capelle-Laize *et al.*, 2003], les auteurs proposent d'utiliser cette information, obtenue à partir d'images d'IRM cérébrales, afin de déterminer le contour de la lésion.

### 3.3 État de l'art des méthodes de fusion en imagerie médicale

Nous présentons dans cette section l'état de l'art des méthodes de fusion d'information, de haut niveau, en imagerie médicale. On trouve dans la littérature quatre principales méthodes de fusion d'information : la fusion par le vote, par la théorie des probabilités, par la théorie des possibilités et par la théorie des fonctions de croyance.

#### 3.3.1 Fusion par le vote

##### 3.3.1.1 Principe

La méthode de fusion d'information la plus simple à mettre en œuvre et la plus naturelle est le vote. À partir de décisions, souvent binaires, émises pour chaque classe par plusieurs sources, le vote a pour principe de choisir la classe qui possède le plus d'occurrences. L'un des moyens de procéder est d'utiliser plusieurs classifieurs, chaque classifieur permettant l'obtention d'une décision binaire pour chacune des classes.

Lorsque plusieurs sources d'information sont disponibles, un classifieur peut être construit pour chacune des sources. Un vote à partir des décisions émises par chacun des classifieurs permet de choisir une classe en tenant compte des différentes sources. Cette approche est intéressante mais la performance est limitée lorsque le nombre de sources considéré est réduit. Une autre approche consiste à utiliser le vote lorsqu'une seule source d'information est disponible et que de nombreux classifieurs, construits indépendamment, répondent différemment. L'intérêt, en apprentissage supervisé notamment, est que cette manière de procéder permet d'éviter le sur-apprentissage des données. L'arbre de décision étant un classifieur qui sur-apprend les données [Breiman, 2001], Breiman propose par exemple de construire de multiples arbres à partir de sous-ensembles aléatoires de données d'apprentissage. Il montre que cette méthode d'ensembles, se focalisant moins sur les données d'apprentissage, est plus pertinente qu'en utilisant un unique classifieur optimisé. Notons que plusieurs méthodes d'ensembles sont proposées dans la littérature [Freund et Schapire, 1996; Breiman, 1996; Ho, 1998] et permettent d'améliorer les performances en classification.

Plusieurs études ont porté sur la comparaison de la fusion par vote avec les approches présentées dans la suite de ce document [Xu *et al.*, 1992; Yager, 2001]. Elles montrent que le vote reste moins performant que les méthodes basées sur des approches probabilistes, possibilistes ou par la théorie des fonctions de croyance.

### 3.3.1.2 État de l'art

En imagerie médicale, peu d'études portent sur la fusion par vote. En effet, les méthodes ont davantage été développées dans le cadre de problèmes d'apprentissages supervisés, et il est en imagerie médicale difficile, notamment dans les problème de segmentation, de définir une vérité terrain. Dans [Dumont *et al.*, 2007], les auteurs proposent de segmenter de manière supervisée des images médicales de la rétine par une méthode d'ensemble d'arbres de décision. La méthode est intéressante car elle permet un gain en généralité. Dans [Lelandais *et al.*, 2010], les auteurs reprennent la méthode afin de classifier des images d'alvéoles pulmonaires. Le vote, appliqué à la combinaison de classifieurs, est intéressant en vue de segmenter ou de classifier des images. Cependant, cette méthode ne semble pas avoir été investiguée dans le cadre de la fusion de plusieurs images médicales, ceci étant certainement dû à la simplicité de la méthode, la rendant inadaptée à la fusion d'une faible quantité de données imparfaites.

### 3.3.2 Fusion par approche probabiliste

#### 3.3.2.1 Principe

L'approche probabiliste, comme nous l'avons vu au chapitre précédent, permet de modéliser l'incertitude en affectant à une donnée une probabilité d'appartenance à chaque classe. Ayant une unique mesure pour décrire la probabilité d'appartenance d'une donnée à une classe, l'imprécision ne peut pas être distinguée de l'incertitude. Il y a donc une confusion entre les incertitudes dues au bruit, et les imprécisions dues à un manque de connaissance. Confondues dans l'approche probabiliste, ces deux imperfections sont indûment nommées incertitudes. Cette théorie a cependant pour l'avantage d'avoir été beaucoup étudiée et de posséder un formalisme précis régie par le théorème de Bayes. La théorie bayésienne de la décision a été introduite dans l'objectif de répondre à une problématique de classification dont le principe est de maximiser la probabilité d'avoir une classe sachant les observations. Afin de combiner les probabilités estimées à partir de plusieurs sources d'information, on recourt à l'utilisation de la règle de Bayes :

$$P(X|S_1, \dots, S_N) = \frac{P(X)P(S_1, \dots, S_N|X)}{P(S_1, \dots, S_N)} \quad (3.2)$$

où  $X$  et  $S_1, \dots, S_N$  sont respectivement les classes et l'ensemble des sources d'information à fusionner. Sous l'hypothèse d'indépendance statistique entre les sources, ce modèle de combinaison peut être simplifiée en un simple produit des probabilités. Notons que dans la plupart des applications, l'indépendance cognitive est admise.

En outre, notons que l'on peut rencontrer dans la littérature d'autres opérateurs de combinaison tels que le maximum, le minimum ou la moyenne des probabilités estimées pour chaque source [Xu *et al.*, 1992]. Dans [Pieczynski, 2003], l'auteur propose d'utiliser l'opérateur de combinaison de Dempster-Shafer pour la fusion de probabilités dans un contexte markovien.

À la différence de la méthode de vote, la fusion par approche probabiliste consiste en la fusion de probabilités estimées, et la décision n'est à ce stade pas encore prise. Pour décider, on recourt à une règle de décision. La plus employée est le maximum *a posteriori*.

### 3.3.2.2 État de l'art

Hurn *et al.* [1996] proposent une méthode de fusion d'images qu'ils évaluent sur des images médicales, TDM et TEMP dans un premier temps, et IRM dans un second temps. L'objectif est de segmenter les différentes régions du cerveau. Ils proposent un modèle basé sur les champs de Markov permettant, d'une part de tenir compte du bruit en modélisant chaque classe par une distribution gaussienne, et d'autre part d'obtenir une image segmentée tirant partie des différentes modalités d'imagerie. L'approche est intéressante car elle permet, lorsque deux classes sont confondues sur une modalité, de tirer parti de la complémentarité des autres modalités afin de lever l'ambiguïté. Néanmoins, plutôt que d'affecter à un voxel une probabilité sur un ensemble de classes lorsqu'il y a confusion, les auteurs sont amenés à affecter une probabilité sur l'une des classes. Cette limite est due à l'incapacité de la théorie des probabilités à modéliser l'imprécision. Cette limite amène la majorité des auteurs à tirer parti des outils développés dans le cadre de la théorie des possibilités et des fonctions de croyances pour réaliser la fusion d'information.

### 3.3.3 Fusion par approche possibiliste

#### 3.3.3.1 Principe

La théorie des possibilités [Zadeh, 1978; Dubois et Prade, 1987] dérive de la théorie des ensembles flous [Zadeh, 1965] que l'on a introduite section 2.2.6.1. Cette dernière permet, dans le cadre de la reconnaissance de formes, d'affecter à une donnée un degré d'appartenance relatif à une hypothèse. Un degré d'appartenance est par définition différent d'une probabilité. Si l'approche probabiliste a l'avantage de pouvoir modéliser l'incertitude, l'approche floue a l'avantage de pouvoir modéliser l'imprécision en utilisant une unique mesure pour décrire l'appartenance d'une donnée à une hypothèse. De ce fait, elle a également pour désavantage de ne pas pouvoir modéliser l'incertitude. Deux mesures sont nécessaires pour décrire les données afin

de modéliser à la fois l'incertitude et l'imprécision. La théorie des possibilités a été proposée dans cet objectif.

La théorie des possibilités repose sur les mesures de possibilité et de nécessité. La mesure de possibilité d'un événement  $A$  parmi l'ensemble des hypothèses considérées  $\Omega$  est noté  $\Pi(A)$ . Elle peut être vue comme une mesure floue, et permet de représenter l'imprécision. Elle a pour propriété :

$$\Pi(A \cup B) = \max(\Pi(A), \Pi(B)). \quad (3.3)$$

À cette mesure vient s'ajouter la mesure de nécessité,  $N(A)$ , qui s'interprète comme la mesure d'impossibilité de l'événement contraire. Elle permet de représenter l'incertitude et a pour propriété :

$$N(A \cap B) = \min(N(A), N(B)). \quad (3.4)$$

Ces deux mesures sont liées par la relation suivante :

$$N(A) = 1 - \Pi(\bar{A}), \quad \forall A \subseteq \Omega. \quad (3.5)$$

Dans de nombreuses applications, on recourt à l'utilisation de méthodes floues pour estimer les degrés de possibilité. La modélisation des incertitudes est alors réalisée de manière implicite, sans que l'on cherche à les modéliser, grâce à la relation 3.5 puisqu'elle permet de déduire une nécessité à partir d'une possibilité.

À partir de l'estimation de degrés de possibilité sur des images multi-modales, leur fusion peut être effectuée. La théorie des possibilité offre un important choix d'opérateurs de combinaison. Parmi eux, on trouve les opérateurs *t-normes* et *t-conormes*, généralisant les opérateurs d'intersection et d'union de la théorie des ensembles [Bloch, 1996a]. Leur comportement est respectivement conjonctif et disjonctif. Des exemples de *t-norme* sont l'opérateur minimum ou le produit, et le maximum pour les *t-conormes*. D'autres opérateurs de type moyenne peuvent également être utilisés, et ont pour intérêt d'être idempotent. Les opérateurs dont le comportement est ni conjonctif ni disjonctif sont dits hybrides [Zimmermann et Zysno, 1980]. Dans [Dubois et Prade, 1987], les auteurs proposent un opérateur de combinaison pondéré afin de tenir compte de la fiabilité des sources. Comme nous pouvons l'observer, l'avantage de la théorie des possibilité réside dans le choix très large d'opérateurs de fusion qu'elle offre.

La sortie des opérateurs de fusion ne correspond pas à une décision, mais à des degrés de possibilité vis-à-vis de chaque classe. Le choix d'une classe se fait alors à partir du maximum des degrés d'appartenance.

### 3.3.3.2 État de l'art

Dou *et al.* [Dou *et al.*, 2007] proposent d'intégrer un modèle flou pour la segmentation des tumeurs sur des images d'IRM cérébrales en T1, T2 et DP (Densité de Protons). Les auteurs proposent de tirer parti des trois types d'information pour obtenir une segmentation pertinente. Les contrastes au niveau des tissus sont différents entre les 3 images IRM. Un modèle flou a été proposé pour chaque modalité à partir de connaissances *a priori*. Ces modèles permettent d'attribuer à chaque voxel de chaque modalité un poids entre 0 et 1 relatif à l'appartenance de chaque voxel à la tumeur. Afin de combiner les trois sources d'information, les auteurs proposent d'utiliser la moyenne géométrique. Ainsi, sur chaque image de la coupe 3-D résultante, un voxel ayant une valeur proche de 1 est considéré comme appartenant à la tumeur, alors qu'un voxel proche de 0 est considéré comme appartenant au tissu sain. En dernier lieu, pour obtenir le volume tumoral final, les auteurs proposent une méthode de sélection des voxels basée sur leur degré d'appartenance au volume tumoral en tirant partie également de la connexité liant les voxels entre eux. L'approche semble pertinente car l'étude comparative entre les volumes obtenus automatiquement et les volumes segmentés par un expert sont très proches.

Dans [Boussion *et al.*, 2003], les auteurs proposent une méthode de détection des foyers épileptogènes afin de mettre en place une aide au diagnostic pré-chirurgicale. Quatre modalités d'image sont utilisées : deux modalités TEMP acquises en l'absence et en présence de crise d'épilepsie et deux modalités TEP acquises avec les traceurs  $^{18}\text{F}$ FDG et flumazenil<sup>1</sup>. Afin de considérer l'imprécision induite par la faible résolution des images et la présence d'effet de volume partiel, les auteurs proposent d'utiliser la logique floue et la théorie des possibilités. Un degré d'appartenance entre 0 et 1 est attaché aux voxels de chaque modalité et permet de les qualifier comme des tissus sains ou pathologiques. Afin de fusionner les quatre modalités, un opérateur de fusion adapté est utilisé. Ce dernier a un comportement « sévère » (combinaison conjonctive) lorsque les sources sont non-conflictuelles, et « prudent » (compromis entre les combinaisons conjonctive et disjonctive) lorsque les sources sont conflictuelles. Par ailleurs, lors du processus de fusion, les auteurs proposent de pondérer chaque modalité par un poids connu *a priori*, conférant ainsi à la méthode une prise en compte de la fiabilité propre à chaque modalité. Une étude de la méthode de détection des foyers épileptogènes sur douze patients a donné des résultats qui concordent à la référence pour onze des patients, où la référence est obtenue par l'utilisation d'électrodes profondes et l'exérèse chirurgicale.

---

1. Permet l'étude des récepteurs aux benzodiazépines dont la densité semble inversement corrélée à la perte neuronale [Henry *et al.*, 1993].

Colin et Boire [Colin et Boire, 1999] proposent d'utiliser la théorie des possibilités pour la fusion d'images IRM et TEMP du cerveau. Leur objectif est de segmenter la matière blanche (MB), la matière grise (MG), le liquide céphalo-rachidien (LCR) ainsi que la matière grise hypoperfusée (MGH). Les histogrammes des deux modalités semblent chacun pouvoir distinguer trois classes (MB, MG et LCR) que les auteurs proposent de représenter sur une échelle de niveaux de gris par des trapèzes. Pour chaque modalité, trois distributions de possibilité trapézoïdales représentent chacune des hypothèses pouvant être discriminées. La fusion des différentes modalités proposée par les auteurs engendre neuf sous-ensembles, qu'ils proposent de transférer sur les classes MB, MG, LCR et MGH. Ceci leur permet d'obtenir pour chaque voxel un degré de possibilité relatif à chacune des quatre classes. Les auteurs proposent une représentation des images fusionnées fonction des degrés de possibilité de chaque voxel. Cette image paramétrique offre une visualisation des différentes régions plus pertinente qu'en considérant initialement les deux modalités.

Plus récemment, Montagner *et al.* [Montagner *et al.*, 2005, 2007] ont repris la modélisation trapézoïdale pour la description des images IRM et TEMP. Néanmoins, ils utilisent un opérateur de fusion plus pertinent, ne nécessitant pas la mise en place d'une interpolation pour mettre la modalité TEMP à l'échelle de la modalité IRM. Considérant les voxels comme des cubes (de plus grande taille en TEMP qu'en IRM), les auteurs proposent d'utiliser un opérateur de fusion spatial tenant compte de la quantité d'information des voxels de la modalité TEMP qui intersectent les voxels de la modalité IRM. L'intérêt est que l'information de la multi-modalité est mieux préservée. Pour mesurer l'intersection des voxels, notons que ces auteurs reprennent la méthode introduite dans [Reveillès, 2001].

La récente méthode proposée par [Dewalle-Vignion *et al.*, 2011], présentée section 2.2.6.2, est utilisée à visée de segmentation d'image TEP. Elle est basée sur la théorie des possibilités. Bien qu'une seule modalité d'image soient présente dans la méthode, les auteurs proposent de fusionner le contenu du volume 3D aux trois plans 2D, obtenus à partir d'images MIP du volume 3D. L'utilisation de MIP, dont la particularité est d'être bien contrasté, induit la présence de multiples sources d'information, d'où l'utilisation de la théorie des possibilités permettant aux auteurs de fusionner l'ensemble des plans. Dans un premier temps, les auteurs proposent d'appliquer l'algorithme FCM [Bezdek, 1981] sur chacun des plans où chaque pixel est décrit par deux caractéristiques : son intensité, et la moyenne des intensités de son voisinage  $3 \times 3$  afin de réduire le bruit. Les degrés d'appartenance obtenus via le FCM, considérés comme des degrés de possibilité [Zadeh, 1978], sont ensuite fusionnés par l'intermédiaire de l'opérateur produit. Enfin, la classe ayant le degré de possibilité maximum est choisie. La méthode est

intéressante car les auteurs tirent parti des outils de fusion, non pas à visée de fusion de multiples images, mais à visée de segmentation d'images faiblement contrastées.

Les méthodes présentées ont été proposées pour la fusion multi-modale d'images médicales. La capacité de la théorie à tenir compte de l'imprécision a été effectuée par l'attribution de degrés d'appartenance relatifs à différentes hypothèses. Néanmoins, ces méthodes ne semblent pas tenir compte de l'incertitude de manière explicite, et tiennent compte de forts *a priori* pour l'estimation des degrés d'appartenance.

### 3.3.4 Fusion par fonctions de croyance

#### 3.3.4.1 Principe

La théorie des fonctions de croyance [Dempster, 1967; Shafer, 1976] a l'avantage de modéliser l'information en assignant à chaque observation une masse de croyance  $m$  vis-à-vis de plusieurs sous ensembles  $A$  de classes. Soit  $\Omega = \{\omega_1, \dots, \omega_k, \dots, \omega_K\}$  l'ensemble des  $K$  classes considérées, également appelé cadre de discernement. L'incertitude peut être modélisée via cette théorie en assignant à chaque classe, appelée singleton ou hypothèse simple, une masse de croyance de façon similaire à la théorie des probabilités. En outre, l'imprécision peut également être modélisée car la théorie permet d'assigner des masses de croyance vis-à-vis de sous ensembles  $A \subseteq \Omega$  de plus haute cardinalité, pouvant être appelés disjonctions ou hypothèses multiples, parmi le cadre de discernement. L'ensemble des masses affectées aux hypothèses doivent respecter la relation suivante :

$$\sum_{A \subseteq \Omega} m^\Omega(A) = 1. \quad (3.6)$$

Ainsi, la théorie des fonctions de croyance a l'avantage de permettre la modélisation des incertitudes et des imprécisions de manière explicite. En outre, notons qu'une fonction de masse peut être vue comme une mesure de possibilité dans le cas particulier où les éléments focaux<sup>2</sup> sont emboîtés [Dubois et Prade, 1990]. Dans ce cas de figure, les fonctions de plausibilité et de crédibilité calculées à partir d'une fonction de masse  $m$ , que nous définissons au prochain chapitre, correspondent respectivement à des mesures de possibilité et de nécessité.

Un autre intérêt de la théorie réside dans l'utilisation de l'ensemble vide. Il permet d'envisager que l'état réel du système observé n'appartienne pas à l'ensemble des classes considérées. On dénote par monde ouvert et monde fermé respectivement les mondes acceptant et n'acceptant pas que l'ensemble vide comme solution du problème.

---

2. Hypothèses dont la masse est non nulle.



Les deux opérateurs de fusion les plus utilisés dans la littérature sont les opérateurs conjonctifs et disjonctifs [Smets, 1993], qui, sous hypothèse d'indépendance cognitive entre les sources, permettent de transférer respectivement les masses de croyance sur les plus petits et sur les plus grands sous-ensembles. La combinaison conjonctive a pour intérêt de réduire les incertitudes et les imprécisions, sous condition que les sources à fusionner soient toutes fiables. La masse assignée à l'ensemble vide, qui est le plus petit sous ensemble, correspond au conflit entre les sources. Lorsqu'au moins une des sources est fiable, mais que l'on ne sais pas laquelle, la combinaison disjonctive est choisie. Elle assure que le résultat de la fusion soit fiable.

Les opérateurs de combinaison conjonctive et disjonctive ne sont pas les seuls proposés dans la littérature. Certaines opérations visent notamment à répartir le conflit induit par la combinaison conjonctive sur certains sous-ensembles [Yager, 1987; Dubois et Prade, 1988]. Plus récemment, Dencœux [2008] a proposé une méthode permettant de généraliser les opérateurs *t-norme* et *t-conorme* de la théorie des possibilités à la théorie des fonctions de croyance.

Dans le cadre de la classification automatique, la dernière étape concerne la prise de décision. Elle est réalisée par la maximisation d'un critère tel que la crédibilité ou la plausibilité.

### 3.3.4.2 État de l'art

La première méthode basée sur la théorie des fonctions de croyance, utilisant la fusion d'information en imagerie médicale, a été proposée par Bloch [1996b]. L'auteur propose une méthode de segmentation d'images IRM double-écho. Trois classes composent l'ensemble des modalités et chacune des modalités permet la distinction d'une classe contre les deux autres. Les images sont entachées ambiguïtés mais présentent l'intérêt d'être complémentaires. L'auteur propose d'utiliser la théorie des fonctions de croyance pour affecter des masses non nulles sur les hypothèses simples et multiples, respectivement relatives aux informations non-ambiguës et ambiguës sur les images. Étant donnée la complémentarité des deux images, leur fusion, par l'opérateur de combinaison conjonctif, a pour intérêt de lever la majeure partie des ambiguïtés. L'autre intérêt est qu'à l'issue de la fusion, les données à la transition entre les régions sont encore représentées sur les hypothèses multiples, signant la présence d'ambiguïtés dues à l'effet de volume partiel. Il résulte de la méthode que ces données sont étiquetés comme appartenant à de multiples hypothèses et ne sont pas attribuées aux hypothèses simples à tort.

Dans [Gautier *et al.*, 1999], les auteurs utilisent la théorie des fonctions de croyance pour la segmentation de la colonne vertébrale à partir d'images IRM. La théorie des fonctions de croyance est utilisée dans l'objectif de mesurer l'appartenance des points d'un contour actif au contour de chaque vertèbre. Pour ce faire, ils proposent de fusionner, pour chaque point

d'un contour actif, deux distributions de masses relatives aux deux distances le séparant des contours actifs sur les coupes inférieure et supérieure. La fusion d'information leur permet ainsi de connaître la pertinence des points. L'application est intéressante dans le sens où elle montre que les fonctions de croyance sont utilisées, non pas à visée de segmentation, mais pour apprécier la pertinence d'une segmentation.

Dans [Muller *et al.*, 2001], les auteurs proposent d'utiliser la théorie des fonctions de croyance pour la fusion de cartes polaires du myocarde à des fins d'assistance au diagnostic médical. Deux modalités d'images, IRM et TEP, sont utilisées. L'imagerie TEP donne une information fonctionnelle sur la consommation en glucose des tissus, et l'imagerie IRM donne quatre informations qui sont la contraction musculaire et l'angle, au repos et à l'effort. Cinq cartes polaires composées de différents segments du myocarde sont disponibles et fusionnées pour évaluer la viabilité myocardique. L'intérêt de la méthode provient de l'architecture de fusion mise en place et de la représentation du résultat à l'issue de cette fusion. Tout d'abord, les images sont modélisées par des fonctions trapézoïdales, considérant non seulement les hypothèses simples mais également les hypothèses multiples pour prendre en compte le doute entre les hypothèses. Notons que ces fonctions sont définies par l'expert médical et sa connaissance *a priori*. Les cartes polaires sont ensuite fusionnées selon une architecture binaire prédéfinie, où les hypothèses de sortie à l'issue de chaque combinaison sont fixées par l'expert médical. Sept hypothèses permettent, après fusion, d'évaluer la viabilité myocardique. Néanmoins, plutôt que de décider en faveur d'une des hypothèses pour chacun des segments, Muller *et al.* proposent de présenter le degré d'appartenance de chacune des hypothèses pour chacun des segments. Cette représentation permet, entre autres, d'offrir à l'expert médical la visualisation du degré de viabilité, du degré de nécrose ou du degré d'ischémie<sup>3</sup> pour chaque segment myocardique.

Rombaut et Zhu [Rombaut et Zhu, 2002b] proposent une méthode de segmentation de tumeurs sur des images IRM double-écho. Pour réaliser la fusion des images, il est nécessaire de définir un cadre de discernement commun. L'originalité de la méthode est que, de manière non supervisée, un même cadre de discernement pour chaque image est construit à partir des cadres de discernement de l'ensemble des images. La fusion, par l'intermédiaire de l'opérateur de combinaison conjonctif, permet alors de tirer parti de la complémentarité des images pour lever les ambiguïtés. Malgré les tests effectués sur seulement deux jeux d'images, la méthode semble parvenir à segmenter les tumeurs de manière relativement efficace.

Capelle-Laize *et al.* [Capelle-Laize, 2003; Capelle-Laize *et al.*, 2004a,b] proposent d'utiliser la théorie des fonctions de croyance pour la segmentation tumorale d'images IRM multi-échocs.

---

3. Diminution de l'apport sanguin artériel.

L'originalité de la méthode vient, non pas de la fusion effectuée entre les différentes images, mais de la fusion des informations de voisinage. Les auteurs partent en effet du principe que les voxels voisins d'un voxel à étiqueter constituent une information importante à prendre en considération car elle permet notamment de rendre la méthode robuste au bruit. Ainsi, la fusion conjonctive de chaque voxel avec son voisinage est effectuée.

Zhang *et al.* [Zhang, 2006; Zhang *et al.*, 2007] proposent de reprendre la méthode précédente pour la segmentation d'images TDM thoraciques, ainsi que pour la segmentation d'IRM rénales [Vivier *et al.*, 2008]. La fusion d'information de voxels voisins a également été utilisée pour la segmentation d'IRM de la prostate dans [Makni *et al.*, 2012].

### 3.4 Conclusion

L'étude des différentes imperfections en début de chapitre a tout d'abord permis de présenter des défauts que l'on rencontre en imagerie, avec en particulier, les incertitudes et les imprécisions. Ces deux imperfections ont respectivement pour origine principale le bruit et l'effet de volume partiel et une attention toute particulière doit leur être accordée dans les problèmes de fusion. Nous avons en outre pu mettre en évidence trois particularités qui concernent les liens entre plusieurs sources d'information telles que la redondance, la complémentarité et le conflit qui doivent également être considérés. Ensuite, quatre approches pour réaliser la fusion d'information ont été présentées. La plus simple est le vote, mais les approches probabilistes, possibilistes, et par la théorie des fonctions de croyance possèdent un formalisme plus intéressant permettant de tenir compte des imperfections. Enfin, l'étude de la littérature sur la fusion d'information en imagerie, à l'aide de la théorie des possibilités et des fonctions de croyance, a largement montré leur intérêt dans leur capacité à modéliser les incertitudes et les imprécisions.

Il ressort de l'étude menée dans ce chapitre que les possibilités et les croyances ont souvent été utilisées en imagerie médicale. La théorie des possibilités a l'avantage d'être très souple, au vu de la grande quantité d'opérateurs de fusion proposée dans la littérature. Bien qu'elle permette de tenir compte à la fois des incertitudes et des imprécisions, les incertitudes sont parfois prises en compte de façon implicite, les outils utilisés pour mesurer les degrés de possibilités étant issus de la théorie des ensembles flous [Dewalle-Vignion *et al.*, 2011]. La théorie des fonctions de croyance est de plus en plus utilisée en imagerie médicale car elle permet de très bien modéliser à la fois les incertitudes et les imprécisions. Il peut s'agir de fusionner des informations provenant de multiples sources d'information [Bloch, 1996b], ou bien de considé-

rer une unique source d'information où les voxels voisins sont vus comme des informations à fusionner [Capelle-Laize *et al.*, 2004a].

Nous pensons qu'il y a un réel avantage à travailler avec la théorie des fonctions de croyance, tant pour sa capacité à modéliser l'incertitude et l'imprécision de manière explicite que pour combiner les informations. Elle est de plus en plus appliquée aux images médicales, et n'a jamais été utilisée pour la segmentation d'images TEP entachées d'une importante quantité d'incertitudes et d'imprécisions. Nous présenterons lors du prochain chapitre la théorie des fonctions de croyance de façon plus approfondie, avec en particulier une présentation des méthodes que l'on trouve dans la littérature pour représenter l'information via cette théorie.



# Chapitre 4

## Théorie des fonctions de croyance

### Sommaire

---

<b>4.1</b>	<b>Introduction</b>	<b>93</b>
<b>4.2</b>	<b>Bases théoriques</b>	<b>95</b>
4.2.1	Définition du cadre de discernement	95
4.2.2	Fonction de masse de croyance	95
4.2.3	Transformations de la fonction de masse	96
<b>4.3</b>	<b>Révision des croyances</b>	<b>97</b>
4.3.1	Combinaison conjonctive	98
4.3.2	Combinaison orthogonale de Dempster	98
4.3.3	Conditionnement	99
4.3.4	Combinaison disjonctive	100
4.3.5	Autres opérateurs de combinaison	100
4.3.6	Affaiblissement	101
<b>4.4</b>	<b>Modélisation des croyances</b>	<b>102</b>
4.4.1	Modèles basés sur une approche probabiliste	102
4.4.2	Approches basées sur des informations de distance	103
4.4.3	Approches en imagerie	106
<b>4.5</b>	<b>Décision</b>	<b>109</b>
<b>4.6</b>	<b>Applications en imagerie</b>	<b>110</b>
<b>4.7</b>	<b>Conclusion</b>	<b>114</b>

---

### 4.1 Introduction

La théorie des fonctions de croyance, également appelée théorie de Dempster-Shafer ou théorie de l'évidence, introduite par Shafer [Shafer, 1976], a pour origine les travaux de Dempster [Dempster, 1967]. Inspirée de la notion des probabilités, qui permet de représenter les connaissances incertaines, la théorie des fonctions de croyance permet également la représentation de connaissances entachées d'imprécisions. En outre, elle permet de représenter le conflit entre

sources d'information. Bien que cette théorie ait été introduite par Dempster et Shafer, puis reprise par Kohlas et Monney [1995], la représentation à laquelle nous nous attachons tout particulièrement est celle proposée par Smets [1990] et appelée modèle de croyance transférable. Ce modèle fait la différenciation entre la représentation des connaissances et la prise de décision.

La plupart des approches en reconnaissance de formes se focalisent sur un unique objectif : décider. Le modèle de croyance transférable distingue deux niveaux : *crédal* et *pignistique*, correspondant respectivement à la modélisation des données d'une part, et à la prise de décision d'autre part. Le niveau crédal (du latin *credo* signifiant *je crois*) comprend une partie statique et une partie dynamique. La partie statique correspond à la modélisation des connaissances apportées par les sources d'information, et la partie dynamique correspond à la révision des différentes sources de connaissances disponibles. Dans ce cadre, la combinaison, ou fusion d'information, s'interprète comme : combiner pour mieux représenter, et *a posteriori* pour mieux décider. Le niveau *pignistique* (du latin *pignus* signifiant *un pari*) correspond à la prise de décision cherchant à minimiser le risque de se tromper.

Cette théorie a montré son intérêt dans diverses applications [Denoeux et Masson, 2012] telles que la prévision du niveau de la mer [Abdallah *et al.*, 2012], la domotique [Pietropaoli *et al.*, 2012] ou la localisation de véhicules [Roquell *et al.*, 2012]. Dans ces applications, l'intérêt est que la combinaison des informations, issues d'avis d'experts ou de données recueillies par des capteurs, permet de prédire un événement, de déterminer une position, ou d'estimer un mouvement.

Ce chapitre est organisé de la façon suivante : la première partie présente les bases théoriques. La deuxième introduit les différentes méthodes de révision des croyances. La troisième partie présente l'état de l'art de la modélisation des données dans le cadre des fonctions de croyance. La quatrième partie décrit brièvement des méthodes de décision, correspondant au niveau *pignistique*. Enfin, pour illustrer l'intérêt des fonctions de croyance, la dernière partie est dédiée à la présentation de quelques méthodes originales, tirant parti des outils de cette théorie, dans divers problèmes d'imagerie. Par ailleurs, pour illustrer les différents principes des fonctions de croyance, des exemples sont fournis en annexe.

## 4.2 Bases théoriques

### 4.2.1 Définition du cadre de discernement

L'ensemble des classes définies dans un cadre probabiliste par  $\Omega = \{\omega_1, \dots, \omega_k, \dots, \omega_K\}$  (où  $\Omega$  représente l'ensemble des  $K$  classes relatives au problème considéré) est appelé cadre de discernement. Les hypothèses, ou ensembles de classes, considérées dans le cadre de la théorie des fonctions de croyance est donné par :

$$2^\Omega = \{A | A \subseteq \Omega\} = \{\emptyset, \{\omega_1\}, \dots, \{\omega_K\}, \{\omega_1, \omega_2\}, \dots, \Omega\}. \quad (4.1)$$

$A$  correspond à une hypothèse pouvant être simple (une classe) ou multiple (au moins deux classes), encore appelée respectivement singleton et disjonction. Notons que  $A$  peut aussi correspondre à l'ensemble vide ( $\emptyset$ ), ce qui permet d'envisager que l'état réel du système observé n'appartienne pas aux hypothèses simples et multiples énoncées.

### 4.2.2 Fonction de masse de croyance

Une distribution de masses, également appelée fonction de masse élémentaire,  $m^\Omega$  est une mesure qui permet de représenter une information en tenant compte de l'incertitude et de l'imprécision pouvant potentiellement être attachée aux données. Une masse attribuée à une hypothèse  $A$ , suivant une valeur numérique, est nommée « masse de croyance » et est définie par :

$$\begin{aligned} m^\Omega : 2^\Omega &\longrightarrow [0, 1] \\ A &\longmapsto m^\Omega(A) \end{aligned} \quad (4.2)$$

telle que :

$$\sum_{A \subseteq \Omega} m^\Omega(A) = 1. \quad (4.3)$$

$m^\Omega(A)$  correspond à la part de croyance allouée à l'hypothèse selon laquelle l'état réel  $y$  du système observé appartient à  $A$ . L'affectation d'une masse non nulle à une hypothèse multiple  $A$  signifie que nous ne sommes pas capables de bien différencier les sous-hypothèses qui la composent, traduisant l'ignorance que nous avons vis à vis des sous-hypothèses de  $A$ . Dans le cadre des fonctions de croyance, une ignorance traduit l'imprécision et l'incertitude.

Smets [Smets, 1990] introduit les notions de monde fermé et de monde ouvert. Un monde est dit fermé lorsqu'aucune croyance n'est attribuée à l'ensemble vide. On a alors  $m^\Omega(\emptyset) = 0$ ,



et un monde est dit ouvert lorsque l'attribution de croyance à l'ensemble vide est permise. Nous verrons dans la suite du document (section 4.3) que l'analyse de la croyance attribuée à l'ensemble vide est liée à l'analyse du conflit. Par ailleurs,  $A$  est dit élément focal si une masse non nulle lui est attribuée.

### 4.2.3 Transformations de la fonction de masse

À partir d'une fonction de masse  $m^\Omega$ , des fonctions de crédibilité ou de plausibilité peuvent être utilisés pour représenter la connaissance sur les données.

La fonction de crédibilité, notée  $bel^\Omega$  pour *belief*, est définie par :

$$\begin{aligned} bel^\Omega : 2^\Omega \setminus \{\emptyset\} &\longrightarrow [0, 1] \\ A &\longmapsto \sum_{B \subseteq A, B \neq \emptyset} m^\Omega(B) \end{aligned} \quad (4.4)$$

Cette fonction de crédibilité correspond à l'ensemble des croyances incluses dans l'élément considéré. Elle mesure donc la quantité totale de croyance allouée à  $A$ , justifiée par les informations disponibles. Notons que la crédibilité s'emploie dans le cadre d'un monde fermé.

Inversement, une fonction de masse peut être déterminée à l'aide d'une fonction de crédibilité par l'intermédiaire de la transformée de Möbius [Kennes et Smets, 1991] :

$$m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|A \setminus B|} bel^\Omega(B) \quad \forall A \subseteq \Omega \quad (4.5)$$

où  $|A \setminus B|$  est le nombre d'éléments de  $A$  qui n'appartiennent pas à  $B$ .

La fonction de plausibilité, notée  $pl^\Omega$ , est définie par :

$$\begin{aligned} pl^\Omega : 2^\Omega \setminus \{\emptyset\} &\longrightarrow [0, 1] \\ A &\longmapsto \sum_{B \cap A \neq \emptyset} m^\Omega(B). \end{aligned} \quad (4.6)$$

Elle correspond à l'ensemble des croyances qui intersectent l'élément considéré. Elle mesure ainsi la quantité de croyance qui pourrait potentiellement être allouée à  $A$ , sous réserve de l'obtention de nouvelles informations.

Notons qu'une fonction de plausibilité peut être déterminée à partir d'une fonction de crédibilité grâce à la relation :

$$pl^\Omega(A) = bel^\Omega(\Omega) - bel^\Omega(\overline{A}). \quad (4.7)$$

Les fonctions  $bel^\Omega$  et  $pl^\Omega$  ont pour intérêt d'attacher aux hypothèses un degré traduisant la crédibilité et la plausibilité propre à une information. Pour tout  $A \subseteq \Omega$ , nous avons les propriétés suivantes :

$$pl^\Omega(A) \geq bel^\Omega(A), \quad (4.8)$$

$$bel^\Omega(A) + bel^\Omega(\bar{A}) \leq 1, \quad (4.9)$$

$$pl^\Omega(A) + pl^\Omega(\bar{A}) \geq 1, \quad (4.10)$$

$$bel^\Omega(A) + bel^\Omega(\bar{A}) = 1 - m^\Omega(\emptyset) \Leftrightarrow pl^\Omega(A) = bel^\Omega(A). \quad (4.11)$$

Par analyse de la répartition des masses de croyance, différents phénomènes peuvent être observés, tels que l'ignorance totale, la certitude totale, la croyance bayésienne ou la croyance consonante.

- L'ignorance totale signifie qu'une masse de croyance non nulle ne peut pas être affectée à une hypothèse autre que  $\Omega$ . Dans ce cas, nous avons la relation :  $m^\Omega(\Omega) = 1$ .
- La certitude est dite totale lorsqu'un des singletons est l'unique élément focal. Ainsi, nous avons  $m^\Omega(\{\omega_k\}) = 1$ .
- Une fonction de croyance est dite bayésienne si aucune croyance n'est associée aux hypothèses autres qu'aux hypothèses simples. Ainsi,  $bel^\Omega(\omega_k) = pl^\Omega(\omega_k) = p^\Omega(\omega_k)$ , où  $p^\Omega$  est une probabilité.
- Une fonction de croyance est dite consonante si tous les éléments focaux sont inclus les uns dans les autres. Ce type de fonction de croyance, introduite par Dubois et Prade [Dubois et Prade, 1990], est équivalente à une distribution de possibilités.

Les intervalles  $[bel^\Omega(A), pl^\Omega(A)]$  mesurent la confiance sur les données. En effet, un petit intervalle signifie que les masses sont davantage réparties sur les hypothèses simples, et inversement, un grand intervalle signifie que les masses sont davantage réparties sur les hypothèses multiples.

### 4.3 Révision des croyances

Dans le cadre du modèle de croyance transférable [Smets, 1990], la révision des croyances intervient dans la partie dynamique du niveau *crédal*. Le but est d'améliorer la modélisation des données en tirant partie de toutes les connaissances disponibles.

Plusieurs méthodes permettent de réviser les croyances telles que la combinaison ou l'affaiblissement. La combinaison consiste à regrouper les informations issues des différentes sources

d'information disponibles. L'affaiblissement consiste à augmenter l'incertitude et l'imprécision d'une distribution de masses qui ne serait pas suffisamment fiable.

Notons que la plupart des règles de combinaison ont été conçues, dans le cadre des fonctions de croyance, sous hypothèse que les sources à fusionner soient distinctes. Cette hypothèse, souvent considérée, n'est cependant pas toujours vraie. C'est pourquoi, Dencœur [Dencœur, 2008] a récemment proposé des opérateurs pour la combinaison de sources non distinctes.

### 4.3.1 Combinaison conjonctive

Soient deux sources fiables et distinctes,  $S_1$  et  $S_2$ , ayant le même cadre de discernement. La combinaison conjonctive de ces sources, dans le monde ouvert, est définie par :

$$\begin{aligned} m_{1\otimes 2}^\Omega : 2^\Omega &\longrightarrow [0, 1] \\ A &\longmapsto \sum_{B \cap C = A} m_1^\Omega(B) m_2^\Omega(C). \end{aligned} \quad (4.12)$$

La combinaison conjonctive est commutative et associative, ce qui permet de généraliser la combinaison à  $J$  sources et de réaliser, dans la pratique, les combinaisons dans l'ordre que l'on souhaite. Nous avons ainsi :

$$m_{1\otimes \dots \otimes J}^\Omega(A) = \sum_{A_1 \otimes \dots \otimes A_J = A} \left( \prod_{j=1}^J m_j^\Omega(A_j) \right) \quad \forall A \subseteq \Omega. \quad (4.13)$$

Par ailleurs il est important de noter que la masse, portant sur l'ensemble vide, croît après combinaison. Elle peut être d'autant plus importante que le nombre de sources à fusionner est important. Cette masse sur l'ensemble vide s'interprète comme le conflit. Deux sources contradictoires induisent un important conflit et deux sources en accord induisent un faible conflit. Outre l'information apportée par la combinaison sur les hypothèses simples et multiples, la combinaison apporte ainsi une information sur le conflit susceptible d'être présent entre les sources. Notons qu'il est possible de ne pas considérer le conflit, dans le cadre d'un monde fermé, en utilisant la combinaison orthogonale de Dempster, visant à normaliser les masses par le conflit.

### 4.3.2 Combinaison orthogonale de Dempster

La combinaison orthogonale de Dempster est une normalisation de la combinaison conjonctive par la masse portant sur l'ensemble vide. Elle est définie par :

$$\begin{aligned}
m_{1\oplus 2}^{\Omega} : 2^{\Omega} \setminus \{\emptyset\} &\longrightarrow [0, 1] \\
A &\longmapsto \frac{m_{1\oplus 2}^{\Omega}}{1 - \kappa} = \frac{1}{1 - \kappa} \sum_{B \cap C = A} m_1^{\Omega}(B) m_2^{\Omega}(C).
\end{aligned} \tag{4.14}$$

où  $\kappa$  est un paramètre égal à la masse de l'ensemble vide dans le cadre du monde ouvert. Il contribue à respecter en monde fermé  $\sum_{A \subseteq \Omega} m_{1\oplus 2}^{\Omega}(A) = 1$  et  $m_{1\oplus 2}^{\Omega}(\emptyset) = 0$ . La valeur de  $\kappa$  est donnée par :

$$\kappa = \sum_{B \cap C = \emptyset} m_1^{\Omega}(B) m_2^{\Omega}(C). \tag{4.15}$$

Cette normalisation, semblant naturelle, a été critiquée par Zadeh [1984] car lorsqu'un important conflit est susceptible d'être présent, il est plus prudent de travailler en monde ouvert. En effet, plutôt que de forcer le système à prendre une décision en monde fermé, on peut choisir en monde ouvert de ne pas prendre de décision en cas de conflit qui témoigne d'une ambiguïté entre plusieurs classes.

### 4.3.3 Conditionnement

Le conditionnement permet de mettre à jour une croyance lorsqu'une proposition  $B \subseteq \Omega$  est vraie. Dans le cadre du monde ouvert, la règle de conditionnement est donnée par :

$$\begin{aligned}
m^{\Omega}(A|B) &= \sum_{C \subseteq \overline{B}} m^{\Omega}(A \cup C) \quad \text{si } A \subseteq B, \\
m^{\Omega}(A|B) &= 0 \quad \text{sinon}
\end{aligned} \tag{4.16}$$

Nous présentons Figure 4.1 un exemple de conditionnement :  $\forall X, A, B \subseteq \Omega$ , si  $A = X \cap B$  et que  $B$  est certain, la croyance initialement attribuée à  $X$  peut être transférée sur  $A$ . Conditionner  $m^{\Omega}$  par un élément  $B \subseteq \Omega$  consiste ainsi à restreindre le cadre des propositions possibles de  $2^{\Omega}$  à celles ayant une intersection non nulle avec  $B$ . Notons qu'un transfert n'a pas lieu d'être effectué lorsque la proposition  $X$  est initialement déjà incluse dans  $B$ , et que la croyance sur  $X$  est transférée sur  $B$  à l'issue du conditionnement si  $B \subset X$ .

Dans le cadre du monde fermé, la règle de conditionnement est dite règle de conditionnement de Dempster et fait intervenir le paramètre de normalisation  $\kappa_C$ , tel que :

$$\begin{aligned}
m^{\Omega}(A|B) &= \kappa_C \sum_{C \subseteq \overline{B}} m^{\Omega}(A \cup C) \quad \text{si } A \subseteq B, A \neq \emptyset, \\
m^{\Omega}(A|B) &= 0 \quad \text{sinon}
\end{aligned} \tag{4.17}$$




Figure 4.1 – Schéma illustrant l’opération de conditionnement. Lorsque la proposition  $B$  est certaine, la croyance attribuée à  $X$  peut être transférée sur  $A$ .

avec

$$\kappa_C = \frac{1}{1 - \sum_{C \in \bar{B}} m^\Omega(C)}. \quad (4.18)$$

L’opération de conditionnement est particulièrement bien adaptée dans le cas où l’on dispose d’une information certaine, mais qui peut être imprécise [Ramasso *et al.*, 2007]. Notons que cette opération peut être vue comme un cas particulier de la combinaison conjonctive qui respecte le conditionnement [Smets, 1990].

#### 4.3.4 Combinaison disjonctive

Il est nécessaire d’utiliser l’opérateur de combinaison disjonctif, lorsque la fiabilité de sources distinctes n’est pas quantifiable, mais que l’on sait qu’au moins l’une des sources est fiable sans savoir laquelle. Smets [1993] a proposé de prendre l’union d’hypothèses plutôt que leur intersection afin d’obtenir une fusion disjonctive. Les masses sont ainsi transférées sur les plus grands sous-ensembles, augmentant l’incertitude et l’imprécision, et ne faisant pas apparaître de conflit. La combinaison disjonctive est définie par :

$$\begin{aligned} m_{1 \oplus 2}^\Omega : 2^\Omega &\longrightarrow [0, 1] \\ A &\longmapsto \sum_{B \cup C = A} m_1^\Omega(B) m_2^\Omega(C). \end{aligned} \quad (4.19)$$

#### 4.3.5 Autres opérateurs de combinaison

Dubois et Prade, dans [Dubois et Prade, 1988], proposent une méthode de combinaison qui, à l’issue de la combinaison conjonctive en monde ouvert, vise à diriger le conflit généré entre deux hypothèses, qui ne s’intersectent pas, vers l’union de ces deux hypothèses. Cette

combinaison est donnée par :

$$m_{1\otimes 2}^{\Omega}(A) = m_{1\otimes 2}^{\Omega}(A) + \sum_{B \cap C = \emptyset, B \cup C = A} m_1^{\Omega}(B) m_2^{\Omega}(C) \quad \forall A \subseteq \Omega, \quad (4.20)$$

où  $B$  et  $C$  sont deux partitions de  $A$ .

Lorsque deux distributions de masses identiques donnent, après combinaison, une distribution de masses différente, la combinaison est dite non-idempotente. Les combinaisons conjonctive, orthogonale et disjonctive présentées jusqu'ici possèdent cette propriété.

La non-idempotence est une propriété qui contraint les sources à être distinctes. Dans la plupart des applications, les sources sont fusionnées sous hypothèse d'une certaine indépendance entre elles. Néanmoins, cette notion, difficile à décrire, n'est pas toujours vérifiée et il devient préférable d'utiliser dans ce cas de figure un opérateur de combinaison idempotent, permettant la fusion de sources non distinctes. L'opérateur moyenne est un opérateur idempotent. Cependant, il ne satisfait pas la propriété d'associativité.

Comme nous l'avons vu dans le chapitre précédent, la théorie des possibilités présente l'avantage de posséder une importante quantité d'opérateurs de combinaison, avec en particulier les opérateurs min et max ayant pour propriétés la commutativité, l'associativité ainsi que l'idempotence. Cette dernière propriété est intéressante car elle permet de fusionner des sources non-distinctes. Afin de généraliser l'utilisation de ces opérateurs à des distributions de masses de croyance, Denœux propose dans [Denœux, 2008] d'utiliser la méthode de décomposition canonique d'une distribution de masses [Shafer, 1976; Smets, 1995], permettant de décomposer une distribution de masses de croyance en distributions de masses simples. Ceci lui permet d'introduire notamment deux opérateurs de combinaison pour la combinaison de sources non-distinctes.

#### 4.3.6 Affaiblissement

L'opération d'affaiblissement a été introduite dans le but de réduire les masses de croyance propres aux sources non fiables. Ainsi, l'opération consiste à transférer une part des croyances sur les plus grands sous-ensembles. Shafer [Shafer, 1976] propose l'affaiblissement suivant :

$$\begin{aligned} \alpha m^{\Omega}(A) &= \alpha m^{\Omega}(A), \quad \forall A \subset \Omega \\ \alpha m^{\Omega}(\Omega) &= 1 - \alpha(1 - m^{\Omega}(\Omega)), \end{aligned} \quad (4.21)$$

transférant une partie des masses de chaque sous-ensemble vers l'ensemble  $\Omega$ . Lorsque  $\alpha = 0$ , la remise en cause d'une source est totale, alors qu'avec  $\alpha = 1$ , aucun affaiblissement n'est

présent et la source est considérée comme fiable. L'affaiblissement tend à augmenter l'incertitude et l'imprécision, mais tend aussi *a posteriori* à diminuer le conflit lorsque la combinaison conjonctive est utilisée.

## 4.4 Modélisation des croyances

Après la définition du cadre de discernement intervient la modélisation des croyances. Sa pertinence influe directement sur la compréhension de la problématique, la modélisation des informations objectives qui l'entourent, ainsi que la connaissance que l'on a des sources d'information et de l'objectif à atteindre. La modélisation de l'information, déjà difficile avec la théorie des probabilités, l'est encore plus dans le cadre des fonctions de croyance où des masses sur des hypothèses multiples sont présentes, et où la règle d'équiprobabilité n'existe pas.

Des méthodes automatiques ont été proposées dans la littérature afin d'affecter des masses de croyance non nulles sur les disjonctions. Les sous-sections suivantes en présentent quelques-unes construites à partir de différents modèles tels que des modèles probabilistes, de distances, ou construits à partir d'informations issues d'une image telles que l'histogramme. Notons que d'autres méthodes de modélisation ont été proposées dans la littérature telles que des méthodes contruites à partir de l'algorithme Expectation-Maximization [Vannoorenberghe et Smets, 2005; Jraïdi et Elouedi, 2007; Denceux, 2013], à partir de l'information de proximité entre les données [Denoeux et Masson, 2004; Masson et Denceux, 2004], ou dérivées d'un espace de données multivarié [Wang et McClean, 2008; Wang *et al.*, 2010]. La construction de modèles dépend fortement de l'application et de la connaissance des données. Nous présentons quelques approches ci-dessous.

### 4.4.1 Modèles basés sur une approche probabiliste

La modélisation la plus simple consiste à associer une masse de croyance sur chaque singleton de la même manière qu'avec une approche probabiliste, puis d'effectuer un affaiblissement (voir section 4.3.6). Des masses non nulles sont affectées aux singletons, ainsi qu'à l'ensemble  $\Omega$ . Dans ce modèle, les disjonctions autres que  $\Omega$  ne sont pas modélisées, et l'on perd largement de l'apport conceptuel de la théorie des fonctions de croyance.

D'autres modèles sont disponibles dans la littérature s'inspirant de modèles probabilistes. Shafer [Shafer, 1976] propose une modélisation à partir d'une mesure de croyance consonante. Dans [Dromigny-Badin *et al.*, 1997], les masses affectées aux hypothèses sont fonction de la significativité des probabilités conditionnelles. À partir d'informations *a priori* ou par ap-

prentissage, des probabilités conditionnelles  $p(\mathbf{x}_j|\omega_k)$  peuvent être déterminées, où  $\mathbf{x}_j$  est une observation selon la source  $j$ . Appriou [Appriou, 1993] propose deux modèles utilisant ces probabilités conditionnelles permettant d'affecter à une source une masse relative à une hypothèse donnée. Le premier modèle, identique à celui proposé par Smets [Smets, 1993], est défini par :

$$\begin{aligned} m_{jk}^\Omega(\{\omega_k\}) &= 0 \\ m_{jk}^\Omega(\overline{\{\omega_k\}}) &= K \\ m_{jk}^\Omega(\Omega) &= 1 - K \end{aligned} \quad (4.22)$$

où  $K = \alpha_{jk}(1 - R_j \dot{p}(\mathbf{x}_j|\omega_k))$  avec  $R_j$  un coefficient de pondération des probabilités lié à la source  $j$  et  $\alpha_{jk}$  est un coefficient d'affaiblissement lié à la classe  $k$ , ainsi qu'à la source  $j$ . Ce paramètre relate de la confiance attachée aux données. Ce modèle donne une information sur une source qui ne serait pas de classe  $\omega_k$ . Le second modèle est défini par :

$$\begin{aligned} m_{jk}^\Omega(\{\omega_k\}) &= \alpha_{jk}K \\ m_{jk}^\Omega(\overline{\{\omega_k\}}) &= \alpha_{jk}(1 - K) \\ m_{jk}^\Omega(\Omega) &= 1 - \alpha_{jk} \end{aligned} \quad (4.23)$$

où  $K = R_j \dot{p}(\mathbf{x}_j|\omega_k)$ . Comme nous pouvons l'observer, les masses sont réparties sur trois hypothèses.

#### 4.4.2 Approches basées sur des informations de distance

Les modèles à base de distances correspondent à des modèles où les masses relatives aux données sont fonction de distances calculées dans l'espace des caractéristiques. Dans le cadre de la théorie des fonctions de croyance, deux modèles ont été introduits dans la littérature. L'un est basé sur l'algorithme des  $k$ -plus proches voisins, l'autre est basé sur la méthode d'apprentissage des  $C$ -moyennes.

##### 4.4.2.1 Modèle basé sur les $k$ -plus proches voisins

L'approche utilisant les  $k$ -ppv (pour  $k$ -plus proches voisins) a été proposée par Dencœur [Dencœur, 1995b] et se base sur des informations de distances. Étant donné un ensemble d'apprentissage  $\{(\mathbf{x}^{(1)}, \omega^{(1)}), \dots, (\mathbf{x}^{(N)}, \omega^{(N)})\}$  où  $N$  correspond à la taille de la base d'apprentissage, l'algorithme des  $k$ -ppv consiste à attribuer, à une nouvelle observation, la classe correspondant à ses  $k$  plus proches voisins. Ainsi, Dencœur propose, à une observation  $\mathbf{x}$ , d'attribuer une masse



de croyance pour chaque élément d'apprentissage  $\mathbf{x}^{(i)}$  selon :

$$\begin{aligned} m^\Omega(\{\omega_k\}|\mathbf{x}^{(i)}) &= \alpha\phi_k(d^{(i)}) \\ m^\Omega(\Omega|\mathbf{x}^{(i)}) &= 1 - \alpha\phi_k(d^{(i)}) \\ m^\Omega(A|\mathbf{x}^{(i)}) &= 0, \quad \forall A \subseteq 2^\Omega \setminus \{\Omega, \{\omega_k\}\} \end{aligned} \quad (4.24)$$

où  $d^{(i)} = d(\mathbf{x}, \mathbf{x}^{(i)})$ ,  $\omega_k$  est la classe de  $\mathbf{x}^{(i)}$ ,  $\alpha$  est un paramètre d'affaiblissement compris entre 0 et 1 et  $\phi_k$  est une fonction décroissante vérifiant  $\phi_k(0) = 1$  et  $\lim_{d \rightarrow \infty} \phi_k(d) = 0$ . Enfin, Dencœux propose d'utiliser pour  $\phi_k$ , notamment lorsque la distance est une distance euclidienne, la relation suivante :

$$\phi_k(d) = e^{-\gamma_k d^2} \quad (4.25)$$

avec  $\gamma_k$  un paramètre positif associé à la classe  $\omega_k$ .

Comme précédemment défini, pour une observation  $\mathbf{x}$  donnée,  $N$  masses de croyance lui sont attribuées. Néanmoins, une masse proche de 0 implique une grande distance  $d$  et il devient alors intéressant d'utiliser seulement les  $k$  plus proches voisins (où  $d$  est faible). Finalement, pour une observation, une masse relative à chaque hypothèse simple  $\{\omega_k\}$  ainsi qu'à l'ensemble  $\Omega$  est obtenue par la règle de combinaison de Dempster.

#### 4.4.2.1.1 Choix des paramètres

Le modèle de Dencœux compte deux paramètres  $\alpha$  et  $\gamma$ . Le premier est un coefficient d'affaiblissement, le second est un coefficient de pondération des distances. Ce dernier permet de tenir compte de la répartition des données d'apprentissage en fonction des classes. Dans [Dencœux, 1995b], Dencœux propose de prendre  $\alpha = 0,95$  et  $\gamma_k = \frac{1}{d_{moy,k}}$ , inversement proportionnel à la distance moyenne entre les données d'apprentissage appartenant à l'hypothèse  $\omega_k$ .

Zouhal et Dencœux [Zouhal et Dencœux, 1995, 1998] proposent une méthode permettant d'optimiser la valeur de  $\gamma_k$ . Cette méthode consiste en la minimisation d'une erreur quadratique sur les  $N$  données de l'ensemble d'apprentissage prises individuellement, c'est à dire selon un protocole *leave one out*. L'erreur est ainsi définie par :

$$E = \frac{1}{N} \sum_{l=1}^N \sum_{k=1}^K \left( \text{Bet}P^{(\ell)}(\{\omega_k\}) - t(\ell)(\{\omega_k\}) \right)^2 \quad (4.26)$$

où  $t(\ell)(\{\omega_k\}) = 1$  si la donnée  $\ell$  correspond à l'hypothèse  $\omega_k$  et 0 sinon. Enfin, l'erreur quadratique est minimisée selon l'algorithme de descente du gradient.

#### 4.4.2.1.2 Version simplifiée

Une quantité conséquente de données d'apprentissage induit un important coût calculatoire. C'est pourquoi Dencœur [Dencœur, 1995a, 2000] propose une version simplifiée des  $k$ -plus proches voisins, construit comme un réseau de neurones avec une architecture particulière. Dans cette version simplifiée, un seul prototype est construit par classe à partir de la base d'apprentissage, ce qui permet une réduction de la complexité.

#### 4.4.2.1.3 Cadre non supervisé

Le modèle de distances proposé par Dencœur nécessite la connaissance *a priori* de la répartition des données. Il faut donc disposer d'une base d'apprentissage pour utiliser ces modèles. Néanmoins, Dencœur et Govaert [Dencœur et Govaert, 1996] proposent une version non supervisée de l'apprentissage par  $k$ -ppv où le nombre de classes  $y$  est déterminé automatiquement. Dans le cas où le nombre de classes est *a priori* connu, celui-ci peut être incorporé à la méthode comme le proposent Capelle-Laize *et al.* [Capelle-Laize *et al.*, 2006].

Concernant la version simplifiée du modèle de distances de Dencœur, étant donné l'utilisation de prototypes de classes, il est aisé de se ramener dans un cadre non-supervisé en utilisant une méthode de classification non supervisée telle que l'algorithme  $C$ -moyennes.

#### 4.4.2.2 $C$ -moyennes évidentiel

Masson et Dencœur [2008] proposent une extension de l'algorithme FCM (*Fuzzy C-Means*) introduit par Bezdek [Bezdek, 1981] et de l'algorithme de clustering proposé par Davé [Davé, 1991] tenant compte des *outliers*<sup>1</sup>. L'apprentissage automatique non supervisé proposé par Masson et Dencœur est appelé Evidential  $C$ -means (ECM), une version du  $C$ -moyennes tenant compte d'hypothèses multiples, ainsi que d'*outliers*. Ainsi, l'apprentissage qu'ils proposent, décrit succinctement ci-après, peut être utilisé dans le cadre de la théorie des fonctions de croyance.

Soient  $V(B)$ , avec la cardinalité  $|B| = 1$ , les barycentres associés aux hypothèses simples. Masson et Dencœur proposent d'associer des barycentres aux hypothèses multiples selon la relation :

$$V(A) = \frac{1}{|A|} \sum_{B \in A, |B|=1} V(B), \quad (4.27)$$

---

1. Données aberrantes, distantes du reste des données

avec  $|A| \geq 2$ . L'apprentissage proposé par les auteurs comprend un critère à minimiser au fur et à mesure des itérations. L'apprentissage permet de déterminer  $M = (m_1^\Omega, \dots, m_n^\Omega)$  l'ensemble des masses affectées à chaque échantillon et  $V$  l'ensemble des clusters.

Le critère à minimiser est donné par :

$$J(M, V) = \sum_{i=1}^n \sum_{A \subseteq \Omega, A \neq \emptyset} |A|^\alpha m_i(A)^\beta d^2(x_i, V(A)) + \sum_{i=1}^n \delta^2 m_i(\emptyset)^\beta, \quad (4.28)$$

devant respecter :

$$\sum_{A \subseteq \Omega, A \neq \emptyset} m_i(A) + m_i(\emptyset) = 1 \quad \forall i \in \{1, \dots, n\}. \quad (4.29)$$

$d^2(x_i, V(A))$  correspond à la distance euclidienne élevée au carré entre un échantillon  $i$  et le cluster correspondant à l'hypothèse  $A$ . Le terme  $|A|^\alpha$  permet de pénaliser les hypothèses de  $\Omega$  de haute cardinalité en fonction du paramètre  $\alpha$ . Le paramètre  $\beta$  permet de contrôler les degrés d'incertitudes. Enfin,  $\delta$  contrôle la quantité de données considérées comme des *outliers*.

Un avantage majeur de l'algorithme ECM est qu'il permet de manière automatique d'affecter des masses sur toutes les hypothèses, exploitant ainsi pertinemment la théorie des fonctions de croyance. Notons que dans [Antoine *et al.*, 2010], l'algorithme a été modifié. Les auteurs proposent, d'une part d'utiliser une distance de Mahalanobis plutôt qu'une distance euclidienne et, d'autre part d'ajouter à l'algorithme la possibilité de tenir compte de contraintes permettant de lier ou de séparer des données dans l'espace des caractéristiques.

### 4.4.3 Approches en imagerie

En marge des méthodes présentées précédemment pour modéliser les croyances d'une façon générale, certaines méthodes ont été proposées dans la littérature dans le cadre spécifique du traitement de l'image.

#### 4.4.3.1 Approche par histogramme

Dans [Rombaut, 1999; Rombaut et Zhu, 2002b], Rombaut *et al.* proposent une méthode non-supervisée d'estimation des masses de croyance par analyse de l'espace des caractéristiques à une dimension. La modélisation, dans le cadre de la segmentation d'image, s'appuie sur l'analyse de l'histogramme. Chacun des pics de l'histogramme correspond à une hypothèse simple et les zones de transition entre les pics correspondent à des hypothèses multiples. La Figure 4.2 présente un exemple d'estimation des masses de croyance pour trois classes à partir de l'histogramme  $h$  d'une image. Nous observons que trois masses sont affectées à la donnée

$x$  et correspondent aux sous-ensembles  $C_2$ ,  $C_{1,2}$  et  $C_{1,2,3}$ . La structure est ainsi consonante et Rombaut et Zhu [2002b] proposent d'affecter à une donnée  $x$  des masses de croyance selon la forme :

$$\begin{aligned}
 m_x(A_1^x) &= K_x(h(x) - h(A_2^x)) \\
 &\vdots \\
 m_x(A_i^x) &= K_x(h(A_i^x) - h(A_{i+1}^x)) \\
 &\vdots \\
 m_x(\Omega^x) &= K_x h(\Omega^x),
 \end{aligned} \tag{4.30}$$

où  $A_1^x \subset A_2^x \subset \dots \subset A_i^x \subset \dots \subset \Omega^x$  et où  $K_x$  est un terme de normalisation défini par  $K_x = \frac{1}{h(x)}$  permettant de respecter la condition  $\sum_{A \in \Omega} m^\Omega(A) = 1$ . Notons que les histogrammes peuvent être entachés de bruit, faisant apparaître des pics secondaires. Les auteurs proposent d'utiliser des intervalles de précision ou le lissage pour éviter ce phénomène.

Cette modélisation est intéressante dans le cadre de la segmentation d'image où l'histogramme est souvent source d'information importante.




Figure 4.2 – Méthode d'estimation des masses de croyance proposé par Rombaut et extraite de [Rombaut et Zhu, 2002b]

#### 4.4.3.2 Approche par morphologie mathématique

Dans [Bloch, 2008], l'auteur présente une méthode tirant partie des opérateurs flous de morphologie mathématique. Elle permet, à partir d'une modélisation floue initiale, de représenter l'imprécision dans la modélisation.

#### 4.4.3.2.1 Morphologie mathématique et ensembles flous

Les opérateurs de morphologie mathématique [Serra, 1983] sont des opérateurs souvent utilisés pour la segmentation d'image car ils permettent, après l'étiquetage de pixels, de modifier cet étiquetage en fonction du contexte spatial. Les opérateurs couramment rencontrés sont la dilatation ( $\delta$ ) et l'érosion ( $\varepsilon$ ). Ils permettent, comme leur nom l'indique, de dilater ou d'éroder une région. Étant donné un élément structurel  $B$ , définissant par exemple le voisinage autour d'un pixel à dilater ou à éroder, les opérateurs de dilatation et d'érosion d'une fonction  $f$  sur l'espace  $\mathcal{S}$  sont donnés par :

$$\delta_B(f)(x) = \sup_{y \in B_x} f(y), \quad (4.31)$$

$$\varepsilon_B(f)(x) = \inf_{y \in B_x} f(y), \quad (4.32)$$

où  $x$  appartient à  $\mathcal{S}$ .

En appliquant séquentiellement ces deux opérateurs sur une image, deux nouvelles opérations morphologiques peuvent être obtenues et sont nommées fermeture et ouverture. La fermeture est obtenue en effectuant une dilatation suivie d'une érosion ( $\varphi = \varepsilon\delta$ ), et l'ouverture en effectuant une érosion suivi d'une dilatation ( $\gamma = \delta\varepsilon$ ).

Dans [Bloch et Maître, 1995], les auteurs présentent des opérateurs morphologiques flous. L'intérêt est que les éléments structurels permettent de mieux représenter l'imprécision entre les différentes hypothèses considérées. Les opérations de fermeture et d'ouverture d'un ensemble flou  $\mu$  par un élément structurel flou  $\nu$  définis sur un espace  $\mathcal{S}$  sont données dans [Bloch, 2008] par :

$$\forall x \in \mathcal{S}, \quad \delta_\nu(\mu)(x) = \sup_{y \in \mathcal{S}} \top[\mu(y), \nu(x-y)], \quad (4.33)$$

$$\forall x \in \mathcal{S}, \quad \varepsilon_\nu(\mu)(x) = \inf_{y \in \mathcal{S}} \perp[\mu(y), 1 - \nu(x-y)], \quad (4.34)$$

où  $\top$  et  $\perp$  sont respectivement les opérateurs de combinaison t-norm et t-conorm introduits dans le cadre de la théorie des possibilités. Notons que  $\mu$  et  $\nu$  prennent leurs valeurs dans l'intervalle  $[0, 1]$  et que  $\nu$ , à l'origine, est égal à 1.

#### 4.4.3.2.2 Modélisation de l'imprécision par morphologie mathématique dans le cadre des fonctions de croyance

Une utilisation de la morphologie mathématique à des fins d'amélioration de la modélisation est proposée dans [Bloch, 2008]. À partir d'une modélisation floue pré-existante sur un ensemble d'hypothèses qui ne s'intersectent pas, Bloch propose de tirer parti des opérateurs de

morphologie mathématique pour transférer une partie des croyances sur les sous-ensembles de plus haute cardinalité.

L'auteur interprète l'érosion et la dilatation comme respectivement la crédibilité et la plausibilité. Soient, par exemple, deux éléments focaux  $m_0^\Omega(A)$  et  $m_0^\Omega(\bar{A})$  tel que  $m_0^\Omega(A) + m_0^\Omega(\bar{A}) = 1$  avec  $A \subset \Omega$ . Une nouvelle fonction de masse  $M^\Omega$  portant sur les hypothèses  $A$ ,  $\bar{A}$  et  $A \cup \bar{A}$  peut être obtenue étant donné un élément structurel flou  $\nu$ , telle que :

$$\begin{aligned} M^\Omega(A) &= bel^\Omega(A) = \varepsilon_\nu(m_0^\Omega(A)) \\ &= 1 - pl^\Omega(\bar{A}) = 1 - \delta_\nu(m_0^\Omega(\bar{A})) \\ M^\Omega(\bar{A}) &= bel^\Omega(\bar{A}) = \varepsilon_\nu(m_0^\Omega(\bar{A})) \\ &= 1 - pl^\Omega(A) = 1 - \delta_\nu(m_0^\Omega(A)) \end{aligned} \tag{4.35}$$

$$\begin{aligned} M^\Omega(A \cup \bar{A}) &= 1 - bel^\Omega(A) - bel^\Omega(\bar{A}) \\ &= \delta_\nu(m_0^\Omega(A)) - \varepsilon_\nu(m_0^\Omega(A)) \\ &= \delta_\nu(m_0^\Omega(\bar{A})) - \varepsilon_\nu(m_0^\Omega(\bar{A})) \end{aligned}$$

L'imprécision est bien prise en compte en utilisant les opérateurs d'érosion et de dilatation puisqu'une partie des croyances, fonction de l'élément structurel, est transférée sur l'union entre les hypothèses. La forme de l'élément structurel, déterminée par apprentissage ou *a priori*, influe directement sur le degré d'imprécision. En effet, un large élément structurel implique un important transfert de croyance sur l'union entre les hypothèses. Notons que les opérateurs d'érosion et de dilatation peuvent respectivement être remplacés par les opérateurs d'ouverture et de fermeture.

Cette méthode proposée par Bloch [2008] est intéressante car elle peut être appliquée dans le domaine spatial d'une image. Elle peut également être appliquée au niveau de l'espace des caractéristiques, et donc être appliquée à d'autres domaines que l'imagerie.

## 4.5 Décision

Dans un processus de classification, l'étape de prise de décision intervient en dernier lieu. L'objectif de la décision est de choisir l'hypothèse qui minimise le risque de se tromper. La théorie des fonctions de croyance a pour avantage de considérer des singletons et des disjonctions. Ainsi, selon l'application, l'utilisateur peut choisir de décider en faveur d'une hypothèse simple ou d'une hypothèse multiple. Néanmoins, la décision sur les hypothèses multiples est

peu utilisée car l'objectif recherché dans un système automatique de classification est souvent d'avoir une réponse sans imprécision, et donc de porter son choix sur un singleton. Le choix d'une règle de décision dépend donc du problème considéré. Notons que ces règles peuvent en outre intégrer un rejet ainsi que des fonctions de coût [Dencœux, 1997a].

Plusieurs stratégies sont possibles au niveau de la prise de décision. Il est possible de se baser sur le maximum de plausibilité. Ainsi, dans le cas où seules les hypothèses simples sont considérées, nous avons :

$$pl^\Omega(\omega_i) = \max_{\omega_k \in \Omega} pl^\Omega(\omega_k). \quad (4.36)$$

Cette stratégie attribue l'hypothèse de plus haute plausibilité  $\omega_i$  à l'observation considérée. Sur le même principe, le maximum de crédibilité permet de faire le choix de l'hypothèse de plus haute crédibilité :

$$bel^\Omega(\omega_i) = \max_{\omega_k \in \Omega} bel^\Omega(\omega_k). \quad (4.37)$$

Notons que ces deux critères de maximisation sont équivalents lorsque les masses affectées aux hypothèses multiples sont nulles, c'est à dire lorsque l'intervalle  $[bel^\Omega(A), pl^\Omega(A)]$  est nul. Dans ce cas de figure la confiance est maximale.

Dans le cadre des modèles de croyances transférables, Smets [1990] définit le niveau *pignistique* comme dédié à la prise de décision. Selon lui, il est nécessaire au niveau de la décision de se ramener à un cadre probabiliste afin de décider en faveur des singletons. La probabilité *pignistique* notée *BetP* redistribue de façon uniforme les masses vers les hypothèses  $\{\omega_k\}$  selon l'expression suivante :

$$BetP(w_k) = \sum_{A \in \Omega} \frac{|w_k \cap A|}{|A|} m_\odot \quad \forall w_k \subseteq \Omega, \quad (4.38)$$

où  $|\cdot|$  représente la cardinalité du sous-ensemble considéré.

La décision s'effectue alors par maximisation de la probabilité *pignistique* :

$$BetP(\omega_i) = \max_{\omega_k \in \Omega} BetP(\omega_k). \quad (4.39)$$

Bien que la transformation de la croyance en probabilités permette la prise de décision, notons qu'elle engendre une perte d'information.

## 4.6 Applications en imagerie

La théorie des fonctions de croyance est de plus en plus utilisée en imagerie pour ses capacités de modélisation et ses outils de fusion permettant de considérer les voxels comme autant de

sources d'information en imagerie soit monomodalité, soit multimodalité. Cette théorie est notamment utilisée dans différents domaines tels que l'imagerie médicale comme nous l'avons vu dans le précédent chapitre, la vidéo [RAMASSO, 2007; Klein, 2008], le document manuscrit [Kessentini, 2009], l'imagerie satellitaire et aérienne [Bloch *et al.*, 2007; Le Hégarat-Masclé *et al.*, 1997] et l'imagerie sonar [Rominger et Martin, 2010a].

Dans [Le Hégarat-Masclé *et al.*, 1997] une segmentation d'images multi-modales aériennes par la théorie des fonctions de croyance est présentée. Bien qu'ambiguës, les images des différentes sources sont complémentaires. L'originalité de la méthode vient du choix des hypothèses considérées pour la fusion de données. Les hypothèses sont déterminées de manière non supervisée, par analyse de l'intersection des hypothèses sur les différentes sources d'information. Ce procédé permet, après fusion, de lever les ambiguïtés de manière efficace.

Dans [Vannoorenberghe *et al.*, 1999], les auteurs ont proposé d'utiliser la théorie des fonctions de croyance pour la segmentation d'image couleur. Les images possédant trois composantes (rouge, vert et bleu) sont vues comme trois sources d'information dans le processus de fusion. La croyance relative à chaque couleur de chaque pixel est déterminée par l'intermédiaire de distributions gaussiennes. Récemment, Ben Chaabane *et al.* [2009] ont repris cette méthode en modifiant néanmoins la modélisation des croyances. Ils montrent ainsi que le choix d'un modèle de croyance influe sur les résultats de la segmentation. L'évaluation a été réalisée sur des images de cellules simulées en comparant les taux de bonne classification des pixels. Sur leurs images, il s'avère plus pertinent de modéliser la croyance par l'intermédiaire de l'algorithme FCM plutôt qu'avec des distributions gaussiennes.

Dans [Rominger et Martin, 2010a] l'objectif était de recalibrer des images sonar avec des images de référence. Les images, acquises par bateau, sont géoréférencées. Cependant, une imprécision subsiste entre le recalage de l'image de référence et l'image à recalibrer. D'où la nécessité d'effectuer un recalage plus précis que celui effectué par géoréférencement. Le recalage utilisé par les auteurs est basé sur la recherche de la transformation maximisant la similarité entre deux images. Pour mesurer cette similarité, les auteurs proposent dans un premier temps d'étiqueter les images en quatre classes, puis dans un second temps de fusionner les pixels étiquetés de l'image référence et de l'image à recalibrer par l'opérateur de combinaison conjonctif. Un important conflit présent à l'issue de la combinaison de deux pixels signifie qu'ils n'appartiennent pas à la même classe. Ainsi, les auteurs utilisent ce conflit comme indice de similarité.

Vannoorenberghe *et al.* [2003] ont utilisé la théorie des fonctions de croyance pour la segmentation de deux images, l'une de synthèse, l'autre représentant une maison. Leur méthode consiste à étiqueter chaque pixel en fonction de la couleur observée dans l'espace tridimension-



nel. Pour ce faire, ils proposent d'utiliser l'approche distance [Dencœux et Govaert, 1996] dans un cadre non supervisé. Bien que cette méthode permette de déterminer le nombre de classes de manière automatique, les auteurs montrent, sur l'image de synthèse, que la méthode tend à surestimer le nombre de classes. Notons que Capelle-Laize *et al.* [2006] proposent de modifier la méthode pour que le nombre de classes puisse être choisi par l'utilisateur. Cela a pour intérêt de permettre de quantifier les images présentant des scènes naturelles, et ainsi de les compresser. Par ailleurs, le résultat de l'étiquetage étant bruité, Vannoorenberghe *et al.* [2003] proposent d'effectuer comme post-traitement une convolution crédale. L'objectif est de tenir compte des imperfections associés aux pixels des images. Pour ce faire, ils proposent d'affecter des masses de croyance à chaque pixel en fonction du résultat du premier étiquetage, et de fusionner chaque pixel avec son voisinage  $3 \times 3$  par l'opérateur de combinaison conjonctif. En premier lieu, les auteurs montrent que le résultat de la segmentation est nettement amélioré. En second lieu, ils montrent l'apport de la masse affectée à l'ensemble vide. Celui-ci, interprété comme le conflit, est très faible dans les zones homogènes des images, et très élevé au niveau des contours.

Plusieurs auteurs ont repris cette méthode à visée de segmentation d'images. Bacauskiene et Verikas [2004] l'ont également utilisé en guise de *post*-traitement pour l'amélioration de la segmentation d'images couleurs. Des masses de croyance relative à chaque singleton, ainsi qu'à l'ensemble  $\Omega$ , sont affectées à chaque pixel. Les pixels du voisinage, pondérés par des poids fonction de la distance les séparant du pixel considéré, sont alors fusionnés par l'opérateur de fusion de Dempster-Shafer. Appliquée à toute une image, chaque pixel possède une masse par classe tenant compte de l'information contextuelle. La maximisation des masses permet finalement d'améliorer la segmentation.

Comme nous l'avons vu lors du précédent chapitre, des auteurs proposent d'utiliser cette méthode dans l'objectif de segmenter des images médicales. Elle est appliquée aux images d'IRM cérébrales [Capelle-Laize *et al.*, 2004a,b], aux images TDM thoraciques [Zhang *et al.*, 2007], aux images d'IRM rénales [Vivier *et al.*, 2008] et de la prostate [Makni *et al.*, 2012].

Dans [Capelle-Laize *et al.*, 2004a,b], trois modèles à base de vraisemblances [Shafer, 1976; Appriou, 1993] et de distances [Dencœux, 1995b] ont été évalués afin d'associer à chaque voxel des masses de croyance vis à vis des différentes hypothèses considérées. Le modèle de distances, par comparaison à une segmentation manuelle effectuée par un expert, semble donner les meilleurs résultats. Notons que les modèles utilisés nécessitent un apprentissage de manière à associer à chaque classe un prototype tel qu'ici : la moyenne et la variance des niveaux de gris. Une étude comparative révèle que l'algorithme EM (Expectation-Maximisation) effectuée

une pré-segmentation plus pertinente que les algorithmes des k-moyennes et des FCM (Fuzzy-C-Means). La combinaison conjonctive de chaque voxel avec son voisinage, affaibli en fonction de la distance au centre du voxel courant, est ensuite effectuée. Elle permet de réduire le bruit dans les régions à segmenter. L'autre intérêt de la méthode réside dans l'analyse du conflit correspondant aux masses affectées à l'ensemble vide. Plus grande est sa valeur, plus importante est l'ambiguïté. Elle est d'autant plus grande que l'information dans le voisinage diffère, signant la présence de bruit ou d'une transition entre deux régions. L'ambiguïté à la transition entre les régions étant particulièrement importante par rapport au bruit, l'information conflictuelle est vue comme une manière de détecter les contours.

Du fait de la mauvaise gestion des conflits au niveaux des contours des organes à segmenter, dus notamment à l'effet de volume partiel, Zhang *et al.* [2007] proposent d'inclure à la méthode un processus itératif où chaque voxel bien classé par le système, au sens d'un critère de maximum de probabilité *pignistique*, se voit être affecté d'une fonction de masse certaine au fur et à mesure des itérations. De même, un second processus itératif, associé à un seuil qui décroît, permet de limiter le rejet. Cette contribution offre à la méthode l'aptitude à gérer le conflit constaté en présence de bruit ou à la transition entre les régions. Dans [Vivier *et al.*, 2008], la méthode est utilisée à des fins de segmentation d'images IRM rénales.

Récemment, Makni *et al.* [2012] ont proposé de reprendre la méthode introduite par Capelle-Laize *et al.* [2004a] pour la segmentation d'IRM de la prostate. La modélisation des données est effectuée par l'intermédiaire de l'algorithme ECM décrit section 4.4.2.2, que les auteurs proposent de modifier pour que ce dernier tienne compte du contexte spatial. Ils proposent d'intégrer la méthode de fusion du voisinage, par l'intermédiaire de l'opérateur de combinaison conjonctif, au sein de l'algorithme ECM, ce qui leur permet de tenir compte des données bruitées dans la mise à jour des barycentres. Leur auteurs nomment leur méthode MECM, pour *Modified Evidential C-Means*.

L'ensemble des applications, basées sur la fusion de l'information de voisinage, est intéressant car il témoigne du caractère générique de la méthode. Enfin, elle fournit une perspective intéressante dans le cadre de l'imagerie multimodale. Il est en effet envisageable de fusionner les voxels autres que les voxels du voisinage, c'est à dire les voxels provenant de modalités différentes ou multi-traceurs.

## 4.7 Conclusion

La théorie des fonctions de croyance a trouvé de nombreuses applications comme nous l'avons montré précédemment. La tâche la plus difficile est la modélisation des données. En effet, bien que la théorie des fonctions de croyance permette la manipulation d'hypothèses multiples, il peut être très difficile d'en tenir compte dans le sens où l'incertitude et l'imprécisions attachée à l'information peut s'avérer difficile à quantifier, donc à modéliser. Néanmoins, nous avons pu voir que des outils existent et permettent de modéliser l'information de manière automatique.

La révision des croyances offre comme possibilité la prise en compte de plusieurs sources d'information. La combinaison conjonctive, notamment, vise à réduire les éventuelles incertitudes et imprécisions ou à augmenter le conflit lorsque les sources sont en désaccord.

D'après la représentation donnée par Smets [Smets, 1990] appelée modèle de croyance transférable, deux niveaux sont utilisés dans le cadre d'un processus de classification : le niveau *crédal* permet la modélisation et la révision des informations et le niveau *pignistique* permet la prise de décision. Au niveau *pignistique*, bien que Smets recommande la conversion des croyances en probabilités, un large choix de stratégies de prise de décision est offert, puisque sont notamment quantifiables la fiabilité et le conflit.

Enfin, nous avons présenté des applications de la théorie des fonctions de croyance dans le domaine de l'imagerie. Nous avons pu observer qu'elle peut être appliquée pour divers problèmes tels que la segmentation d'image, le recalage d'images ou la détection de contours, prouvant son grand intérêt.

La dernière approche présentée dans ce chapitre a, en particulier, été appliquée à la segmentation d'images mono et multi-modales TDM et IRM. L'utilisation de cette approche pour segmenter les images TEP, étant entachées d'une importante quantité de bruit et présentant de nombreuses ambiguïtés dues à la présence d'effet de volume partiel, pourrait s'avérer avantageuse. En effet, la théorie des fonctions de croyance sur laquelle elle s'appuie semble tout à fait adaptée à la segmentation d'images présentant ces imperfections car elle permet de distinguer l'incertitude et l'imprécision des données. L'utilisation de cette théorie semble également intéressante en vue de fusionner des images TEP multi-traceur dont nous disposons. Nous tirerons donc parti des outils de cette théorie et proposerons une méthode pour segmenter et fusionner nos images TEP tout en tenant compte de leurs imperfections. Dans les deux prochains chapitres nous présenterons, dans un premier temps, une méthode de segmentation des images TEP basée sur la théorie des fonctions de croyance, et leur fusion dans un second temps,

l'objectif étant de segmenter les tumeurs et de créer des images paramétriques afin d'aider le radiothérapeute à mettre en place le *dose painting*.



# Chapitre 5

## Segmentation d'images TEP mono et multi-traceurs

### Sommaire

---

<b>5.1</b>	<b>Introduction</b>	<b>117</b>
<b>5.2</b>	<b>Segmentation mono-traceur</b>	<b>120</b>
5.2.1	EVEII	120
5.2.2	EVEII <sub>3</sub>	126
5.2.3	Réduction des imprécisions	127
5.2.4	Prise de décision	128
<b>5.3</b>	<b>Segmentation multi-traceurs</b>	<b>129</b>
5.3.1	Cadre de discernement	129
5.3.2	Estimation des masses de croyance	130
5.3.3	Fusion des images TEP multi-traceurs	131
5.3.4	Prise de décision	132
<b>5.4</b>	<b>Conclusion</b>	<b>133</b>

---

### 5.1 Introduction

Comme nous l'avons vu lors des chapitres 1 et 2, la présence de bruit et d'effet de volume partiel dans les images TEP rend difficile leur segmentation. Bien que de nombreuses méthodes aient été proposées dans l'objectif de les segmenter, il n'existe pas actuellement de consensus sur la meilleure méthode [Zaidi et El Naqa, 2010]. Par ailleurs, la plupart des méthodes ont été proposées pour la segmentation d'images TEP au  $^{18}\text{FDG}$  (traceur du métabolisme glucidique), alors que nous nous intéressons également à des images TEP à la  $^{18}\text{FLT}$  (traceur de la prolifération cellulaire) et au  $^{18}\text{FMiso}$  (traceur de l'hypoxie) qui présente des différences par rapport aux images  $^{18}\text{FDG}$  en matière de niveau de bruit et de contraste nécessitant une approche s'adaptant à différentes images.




Figure 5.1 – Schéma donnant les différentes étapes de la méthode de segmentation mono-traceur.

Nous proposons une nouvelle méthode, nommée *Evidential Voxel-based Estimation of Imperfect Information* (EVEII), basée sur la théorie des fonctions de croyance, pour la segmentation des images mono-traceur. Pour cette segmentation, nous proposons trois variantes d'EVEII selon l'estimation de croyances associées aux voxels et la modélisation des imperfections. Comme nous l'avons vu lors du chapitre 2, l'utilisation du contexte spatial pour la segmentation d'images TEP est particulièrement intéressante, notamment en vue de réduire le bruit. L'intérêt de notre méthode est d'utiliser le contexte spatial pour tenir compte de l'incertitude et de l'imprécision. Chacune des images mono-traceur étant caractéristique d'une information physiologique propre (métabolisme glucidique, prolifération cellulaire et hypoxie), nous avons également développé une méthode de segmentation multi-traceurs nous permettant de créer des images paramétriques à visée de *dose painting* (voir section 5.3).

La méthode de segmentation mono-traceur est composée de trois étapes (voir Figure 5.1). La première correspond à la méthode de prise en compte des imperfections, EVEII. Elle permet d'estimer les masses de croyance, à partir d'une seule image, en réduisant les incertitudes dues au bruit tout en modélisant les imprécisions dues à l'effet de volume partiel. La deuxième étape concerne la réduction des imprécisions. Enfin, la dernière étape permet la prise de décision et la réalisation de la segmentation mono-traceur.

La Figure 5.2 présente l'architecture de la méthode de segmentation multi-traceurs. Comme nous pouvons le constater, la méthode reprend le schéma initial de segmentation d'images TEP

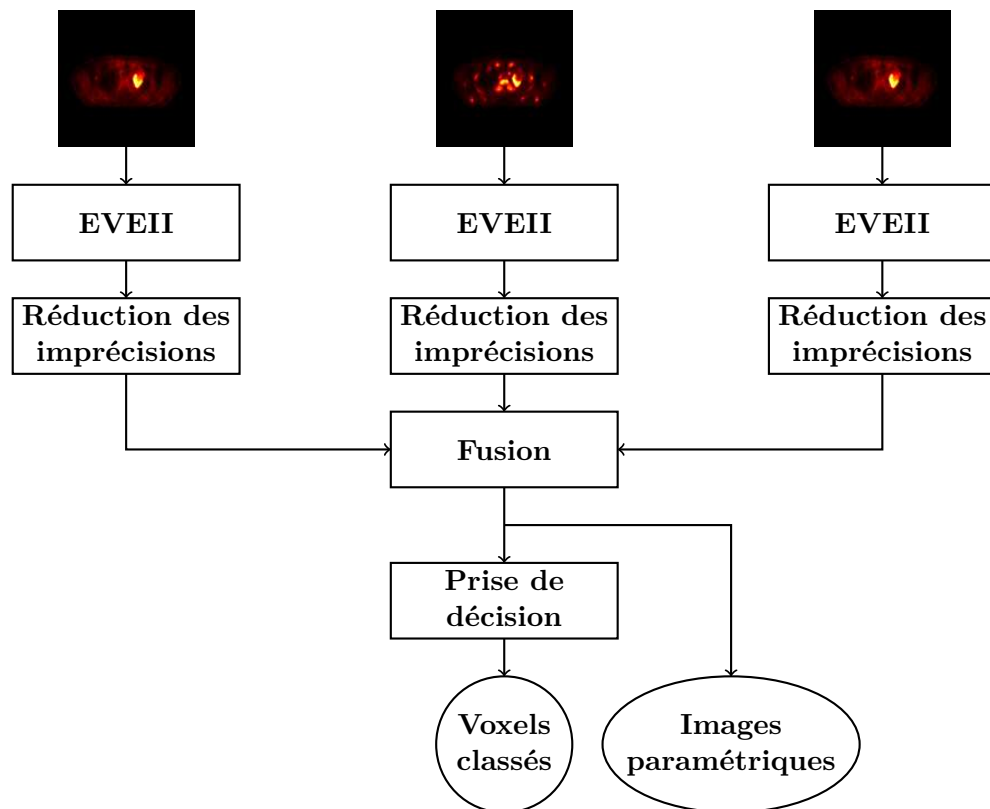


Figure 5.2 – Schéma donnant les différentes étapes de la méthode de segmentation multi-traceurs.



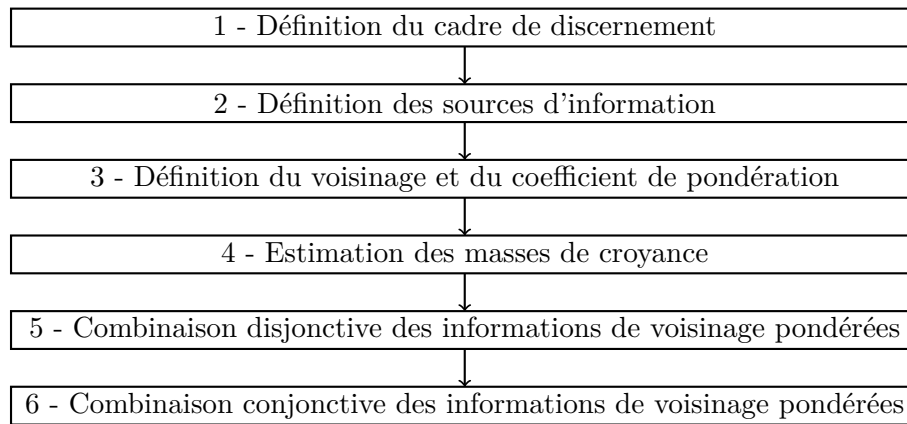


Figure 5.3 – Schéma donnant les différentes étapes d'EVEII.

mono-traceur EVEII jusqu'à l'étape de réduction des imprécisions. Ensuite, elle est suivie d'une quatrième étape de fusion d'information avant l'étape de prise de décision finale. Cette fusion donne naissance à des images paramétriques et la prise de décision finale offre une vue segmentée de différents sous-volumes tumoraux.

Tout d'abord, nous allons présenter notre méthode de segmentation mono-traceur. Ensuite, nous présenterons notre méthode de segmentation d'images TEP multi-traceurs.

## 5.2 Segmentation mono-traceur

### 5.2.1 EVEII

La méthode EVEII se propose de modéliser les imperfections en différenciant les incertitudes et les imprécisions. Les différentes étapes de la méthode sont présentées Figure 5.3. Les deux dernières étapes portent sur des étapes de combinaison. La combinaison disjonctive permet de modéliser les imperfections alors que, comme nous le verrons ultérieurement, la combinaison conjonctive permet de réduire les incertitudes. Nous proposons trois variantes selon l'estimation des croyances et la modélisation des imperfections. Ainsi, pour :

- EVEII<sub>1</sub>, l'estimation des masses est réalisée avec l'algorithme FCM.
- EVEII<sub>2</sub>, l'estimation des masses est réalisée par l'intermédiaire d'un Z-score.
- EVEII<sub>3</sub>, l'estimation des masses est réalisée avec l'algorithme FCM et l'étape de combinaison disjonctive des informations de voisinage pondérées est insérée dans le processus itératif de l'algorithme FCM.

Pour la présentation détaillée de la méthode et de ses variantes, nous les présentons selon l'ordre de la Figure 5.3, à l'exception d'EVEII<sub>3</sub> qui fera l'objet d'un paragraphe particulier en fin de présentation de la méthode.

### 5.2.1.1 Définition du cadre de discernement

Le nombre de classes est lié au contenu de l'information. Pour notre application, nous proposons d'utiliser deux classes  $\omega_1$  et  $\omega_2$  pour représenter les images TEP mono-traceur. La classe  $\omega_2$  correspond aux tissus tumoraux que nous cherchons à segmenter. La classe  $\omega_1$  correspond aux tissus sains avoisinants. Le cadre de discernement est donc défini par :

$$\Omega = \{\omega_1, \omega_2\}, \quad (5.1)$$

et les hypothèses considérées, dans le cadre de la théorie des fonctions de croyance, sont les suivantes :

$$2^\Omega = \{\emptyset, \{\omega_1\}, \{\omega_2\}, \{\omega_1, \omega_2\}\}. \quad (5.2)$$

### 5.2.1.2 Définition des sources d'information

Nous considérons que chaque voxel, dans une image, est une source d'information. Nous notons  $V_i$  chaque source, avec  $i \in \{1, 2, \dots, N\}$  où  $N$  est le nombre total de voxels dans l'image.

Nous proposons de décrire chacune des sources par l'intensité de son voxel. Une seule caractéristique, de bas niveau, est donc utilisée pour décrire les images TEP. Comme nous l'avons vu section 2, l'utilisation de caractéristiques de plus haut niveau en imagerie TEP a surtout pour but d'évaluer la réponse au traitement ou de caractériser l'hétérogénéité des tumeurs.

### 5.2.1.3 Définition du voisinage et du coefficient de pondération $\alpha$

Nous proposons de définir le voisinage de la manière suivante : soit  $\Phi(V_i)$  un ensemble de  $J$  voxels  $V_j$  (avec  $j \in \{1, \dots, J\}$ ) voisins de  $V_i$ , et incluant  $V_i$ . Du fait de la distance géométrique séparant chacun des voxels, nous associons à chaque voxel  $V_j$  un coefficient de pondération  $\alpha_j$  dépendant de la distance géométrique entre  $V_j$  et  $V_i$ . Nous proposons de calculer ce coefficient par :

$$\alpha_j = \exp\left(-\frac{(V_j - V_i)^2}{\sigma^2}\right), \quad (5.3)$$

où  $\sigma$  est un paramètre permettant de régler l'influence du voisinage. Sa valeur dépend de la quantité de bruit dans le signal et de la résolution spatiale du système d'imagerie. Nous pouvons remarquer qu'au centre, où  $V_j = V_i$ , nous avons  $\alpha_j = 1$ , et plus le voxel  $V_j$  est éloigné de  $V_i$ , plus la valeur de  $\alpha_j$  est faible. Nous avons choisi de retenir tous les voisins dont le coefficient  $\alpha_j$  est supérieur à 0,01.

$\sigma$  a été défini en fonction de la résolution spatiale du système de détection, à partir de la largeur à mi-hauteur (FWHM : Full Width at Half Maximum) de la fonction ponctuelle de dispersion (PSF : Point Spread Function, voir section 1.1.1.1.1), par :

$$\sigma = \frac{\text{FWHM}}{2\sqrt{2\ln 2}}. \quad (5.4)$$

En imagerie TEP, la FWHM varie dans le champ de vue de la caméra. Pour notre imageur (Biograph Hi-Rez) la FWHM varie entre 6 et 8 mm. De ce fait, le nombre de voisins dépend de la FWHM retenue. Ainsi, pour  $\alpha_j \geq 0,01$  et une taille d'un voxel de  $4,06 \times 4,06 \times 2 \text{ mm}^3$ , le voisinage est composé de :

- 55 voxels pour un voisinage de taille  $3 \times 3 \times 7$  avec une FWHM = 6 mm.
- 117 voxels pour un voisinage de taille  $5 \times 5 \times 9$  avec une FWHM = 7 mm.
- 151 voxels pour un voisinage de taille  $5 \times 5 \times 11$  avec une FWHM = 8 mm.

La prise en compte du voisinage que nous proposons s'inspire des méthodes présentées dans [Capelle-Laize *et al.*, 2004a; Zhang *et al.*, 2007]. La différence porte sur le fait que le nombre de voisins que nous prenons en compte dépend de la fonction de dispersion linéique de l'appareil d'imagerie plutôt que d'une valeur fixée par l'utilisateur.

#### 5.2.1.4 Estimation des masses de croyance

##### 5.2.1.4.1 EVEII<sub>1</sub>

Comme nous l'avons vu en fin de chapitre 2 (voir section 2.3.3.4, page 69), l'algorithme FCM semble de prime abord, être une méthode bien adaptée à la segmentation des images TEP au <sup>18</sup>FDG. De ce fait, nous avons jugé judicieux de l'utiliser pour initialiser les masses de croyance des images TEP mono-traceur.

Soient  $c_1$  et  $c_2$ , les deux centroïdes représentant respectivement les deux classes  $\omega_1$  et  $\omega_2$ . L'algorithme FCM [Bezdek, 1981] consiste en la mise à jour itérative des centroïdes et des degrés d'appartenance, ou dans notre cas des masses de croyance, de chaque voxel vis-à-vis de chaque classe. Tout d'abord, l'initialisation des masses  $m_{V_i}^0(\{\omega_k\})$  est effectuée par l'intermédiaire de l'algorithme des C-moyennes [MacQueen, 1967]. Cet algorithme permet d'affecter une masse de

croissance égale à 0 ou 1 vis-à-vis de l'une des deux classes pour chacun des voxels. Après cette étape d'initialisation, le processus itératif est effectué. Comme indiqué dans [Zaidi *et al.*, 2002], il consiste en la mise à jour des centroïdes, puis le calcul des masses de croyance  $m_{V_i}^q(\{\omega_k\})$  à chaque itération  $q$ . Chaque centroïde  $c_k$  est mis à jour de la manière suivante :

$$c_k^q = \frac{\sum_{i=1}^N m_{V_i}^{q-1}(\{\omega_k\})^\gamma I_{V_i}}{\sum_{i=1}^N m_{V_i}^{q-1}(\{\omega_k\})^\gamma} \quad (5.5)$$

où  $I_{V_i}$  est l'intensité du voxel  $V_i$  et où  $\gamma > 1$  est un paramètre contrôlant le flou entre les partitions. Les masses de croyance relatives à chacun des singletons pour chacun des voxels sont ensuite calculées de la manière suivante :

$$m_{V_i}(\{\omega_k\}) = \left( \sum_{t=1}^2 \left( \frac{d_{V_i c_t}^2}{d_{V_i c_t}^q} \right)^{\frac{2}{\gamma-1}} \right)^{-1} \quad (5.6)$$

où  $d_{I_{V_i} c_k}$  représente la distance Euclidienne séparant l'intensité du voxel  $V_i$  et le centroïde de la classe  $k$ . Cette étape permet d'associer à chaque voxel une masse de croyance  $m_{V_i}(\{\omega_k\})$  vis-à-vis de chaque singleton  $\omega_k \in \Omega$ .

#### 5.2.1.4.2 EVEII<sub>2</sub>

Certaines images TEP étant peu contrastées et présentant un faible rapport signal sur bruit, nous proposons également une mesure de *Z-score* pour modéliser les masses de croyance et mettre en évidence les hyper-fixations [Matsuda *et al.*, 2007]. Le *Z-score* est donné par :

$$Z_{V_i} = \frac{I_{V_i} - \mu_{No}}{\sigma_{No}}. \quad (5.7)$$

où  $I_{V_i}$  est l'intensité du voxel  $V_i$ , et où  $\mu_{No}$  et  $\sigma_{No}$  sont respectivement la moyenne et l'écart-type, caractérisant la Normalité. Un exemple de détermination des valeurs de  $\mu_{No}$  et  $\sigma_{No}$  est donné Figure 5.4 dans le cas d'une image TEP au <sup>18</sup>FMiso, où la région de normalité a été définie dans le muscle sur l'imagerie TDM [Choi *et al.*, 2010; Eschmann *et al.*, 2007].

À l'issue du calcul des *Z-scores*, leur conversion en masses de croyance est nécessaire. Pour ce faire, nous proposons d'utiliser une fonction  $\mathcal{F}$  de répartition gaussienne  $\mathcal{N}(\mu, \sigma^2)$ , où  $\mu$  correspond à la valeur où la masse de croyance est égale à 0,5 à la suite de la transformation, et  $\sigma$  est un paramètre interagissant sur la pente de la courbe en ce point. De manière à attribuer une masse de croyance proche de 1 en cas d'hyper-fixation, et proche de 0 en cas de normalité, nous avons choisi  $\mu = 2$  et  $\sigma = 1$ . De ce fait, lorsque  $Z_{V_i} = 2$ , la masse de croyance est égale à




Figure 5.4 – Principe de mesure des paramètres  $\mu_{N_o}$  et  $\sigma_{N_o}$  utilisés pour le calcul du  $Z$ -score. Une région musculaire, présentant une fixation modérée dite *normale*, est sélectionnée manuellement sur la modalité d'imagerie TDM (contour vert), puis reportée sur la modalité d'imagerie TEP où les paramètres sont mesurés.

0,5. Ainsi,  $\mathcal{F}(Z_{V_i}) \in [0, 1]$  est une mesure de croyance vis-à-vis de l'hyper-fixation. Nous avons alors :

$$m_{V_i}(\{\omega_2\}) = \mathcal{F}(Z_{V_i}). \quad (5.8)$$

Afin d'avoir une distribution de masses de croyance pour chaque voxel, nous proposons de calculer la masse portant sur l'hypothèse  $\{\omega_1\}$  comme suit :

$$m_{V_i}(\{\omega_1\}) = 1 - m_{V_i}(\{\omega_2\}). \quad (5.9)$$

### 5.2.1.5 Combinaison disjunctive des informations de voisinage pondérées

Nous décrivons à présent la méthode permettant de transférer la croyance concernant les données incertaines et imprécises sur la disjonction  $\{\omega_1, \omega_2\}$ . L'objectif est d'améliorer la modélisation obtenue par l'algorithme FCM ou le  $Z$ -score.

Tout d'abord, le voisinage  $V_j \in \Phi(V_i)$  de chaque voxel  $V_i$  est pondéré par le coefficient  $\alpha_j$  qui lui est associé. En vue de réaliser cette pondération, nous proposons d'utiliser l'opérateur suivant :

$$\begin{aligned} m'_{V_j}(A) &= \alpha_j m_{V_j}(A), & \forall A \neq \emptyset \\ m'_{V_j}(\emptyset) &= 1 - \alpha_j + \alpha_j m_{V_j}(\emptyset). \end{aligned} \quad (5.10)$$

Ainsi, plus grande est la distance entre  $V_j$  et  $V_i$ , plus faible est la valeur de  $\alpha_j$ , et plus important est le transfert vers  $\emptyset$ . À la différence de l'opérateur d'affaiblissement présenté section 4.3.6, cet opérateur permet de transférer une partie des masses de croyance, non pas sur l'hypothèse de plus haute cardinalité  $\Omega$ , mais sur l'ensemble vide  $\emptyset$ . Ce transfert peut être interprété comme un non-engagement envers l'ensemble des hypothèses autres que l'ensemble vide, permettant de réduire l'influence de  $m_{V_j}$  proportionnellement à  $\alpha_j$ .

Après cette étape de pondération, la combinaison disjonctive de chaque voxel  $V_i$  avec son voisinage est effectuée :

$$\mathcal{M}_{V_i}(\cdot) = \bigoplus_{V_j \in \Phi(V_i)} m'_{V_j}(\cdot). \quad (5.11)$$

Ainsi, des masses non nulles sont affectées aux disjonctions. Elles sont d'autant plus élevées que les informations portées par les voxels voisins diffèrent. C'est notamment le cas pour les voxels sujets à l'effet de volume partiel au niveau des contours et pour les voxels situés dans un environnement fortement bruité. Cette combinaison disjonctive permet donc de transférer les masses de croyance relatives aux données incertaines et imprécises sur les disjonctions.

Notre méthode s'inspire de la méthode introduite dans [Capelle-Laize *et al.*, 2004a], proposant de fusionner les informations de voisinage par l'opérateur conjonctif. La différence réside dans le choix de l'opérateur de combinaison. Notre objectif est ici de modéliser les imperfections, et non pas de les réduire comme l'ont proposé Capelle-Laize et ses co-auteurs.

Comme nous l'avons vu section 4.3.4, l'opérateur de combinaison disjonctive peut être utilisé lorsque la fiabilité de sources n'est pas quantifiable, mais que l'on sait qu'au moins l'une des sources est fiable sans savoir laquelle. Dans le contexte du traitement d'images, il est raisonnable de supposer qu'au moins un voxel dans le voisinage donne une information fiable.

La fusion des informations de voisinage, telle que proposée, agit comme un opérateur d'affaiblissement des voxels spatialement ambiguës. L'ignorance augmentant, la fiabilité de chaque source se voit également être augmentée.

### 5.2.1.6 Combinaison conjonctive des informations de voisinage pondérées

Dans l'objectif de réduire l'incertitude, sans impacter sur l'ambiguïté portée par l'imprécision, l'opération inverse, telle que proposée dans [Capelle-Laize *et al.*, 2004a; Zhang *et al.*, 2007], est effectuée. Il s'agit de la combinaison conjonctive des voxels voisins  $V_i$  après affaiblissement sur  $\Omega$  en fonction du coefficient  $\alpha_j$ , tel que :

$$\begin{aligned} \mathcal{M}_{V_k}''(A) &= \alpha_k \mathcal{M}_{V_k}(A), & \forall A \neq \Omega \\ \mathcal{M}_{V_k}''(\Omega) &= 1 - \alpha_k + \alpha_k \mathcal{M}_{V_k}(\Omega). \end{aligned} \quad (5.12)$$

où  $\mathcal{M}_{V_i}''(\cdot)$  est la fonction de masse  $\mathcal{M}_{V_j}(\cdot)$  ayant subi un affaiblissement. Celui-ci permet de réduire l'influence des voxels  $V_j$  éloignés de  $V_i$  avant d'effectuer la combinaison conjonctive. Cette combinaison, effectuée en appliquant la règle de Dempster, peut être à ce moment appliquée car, grâce à la précédente étape de combinaison disjonctive des informations de voisinages, les

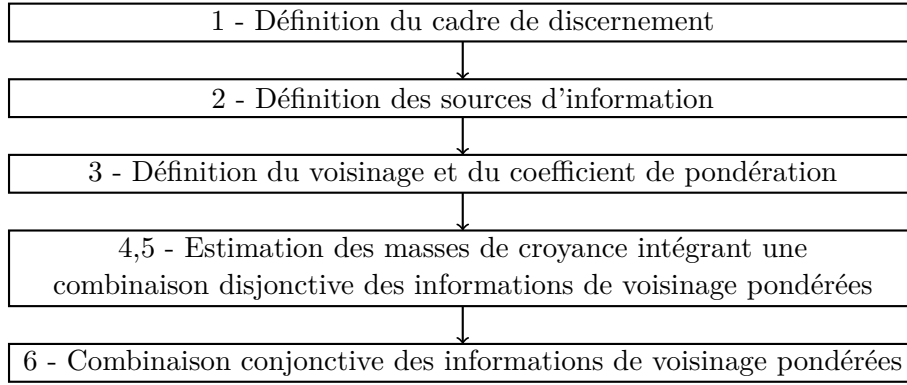


Figure 5.5 – Schéma donnant les différentes étapes d'EVEII<sub>3</sub>.

informations portées par les voxels voisins sont considérées comme fiables. Elle est donnée par :

$$M_{V_i}(\cdot) = \bigoplus_{V_k \in \Phi(V_i)} \mathcal{M}_{V_k}''(\cdot). \quad (5.13)$$

Cette étape permet de lever les ambiguïtés dues au bruit, par transfert de leur croyance sur les singletons, alors que les voxels à la frontière entre régions restent représentés sur les disjonctions.

### 5.2.2 EVEII<sub>3</sub>

Comme nous venons de le voir section 5.2.1.5, la combinaison disjonctive des voxels voisins permet de transférer l'information imparfaite sur les disjonctions à partir d'une distribution de masses initiale obtenue grâce à l'algorithme FCM ou le *Z-score*. Afin de mieux estimer les masses de croyance avec l'algorithme FCM, nous proposons d'y intégrer la combinaison disjonctive des informations de voisinage. Cela permet, comme avec les algorithmes ECM et MECM présentés sections 4.4.2.2 et 4.6, d'estimer les croyances en différenciant les données ambiguës des données non ambiguës. Cette procédure consiste à fusionner les étapes 4 et 5 de la méthode EVEII (voir Figure 5.5). Elle est détaillée comme suit.

Nous avons vu que le processus itératif de l'algorithme FCM est composé d'une première étape de mise à jour des centroïdes et d'une deuxième étape d'estimation des masses de croyance  $m_{V_i}(\{\omega_k\})$  pour chaque voxel avec  $\omega_k \in \Omega$  (voir section 5.2.1.4.1). Nous proposons d'intégrer une troisième étape à ce processus : la combinaison disjonctive des voxels voisins selon les équations 5.10 et 5.11. Cette combinaison disjonctive permet d'obtenir la distribution de masse suivante :

$$m_{V_j}^q = \mathcal{M}_{V_i}. \quad (5.14)$$

Il résulte de cette combinaison que des masses non nulles sont attribuées à la fois aux singletons  $\{\omega_1\}$  et  $\{\omega_2\}$  et à la disjonction  $\{\omega_1, \omega_2\}$  pour chacun des voxels. Plus l'information portée par les voxels voisins est ambiguë, plus la masse portant sur la disjonction est grande. Ce transfert de croyance sur la disjonction permet de mettre à jour les centroïdes lors de l'itération suivante à partir des données non ambiguës uniquement. Ainsi, l'algorithme FCM travaille seulement avec les données certaines et précises, conduisant à une meilleure estimation des masses de croyance.

### 5.2.3 Réduction des imprécisions

Comme nous l'avons vu section 3.2.1, l'imprécision vient d'un manque de connaissance inhérent à l'effet de volume partiel. Celui-ci résulte d'une contamination des structures voisines et conduit à une sous-estimation du volume des lésions en TEP (voir section 3.2.1). Plus faible sont le contraste et le volume de la lésion, plus important est l'effet de volume partiel [Erlandsson *et al.*, 2012]. L'objectif, ici, est de réduire l'imprécision en fonction du contraste et du volume de la lésion.

L'idée est d'intégrer une connaissance *a priori* pour réduire l'imprécision à la suite de l'étape d'EVEII. À cet effet, nous proposons d'utiliser un *a priori* représenté sous forme d'une fonction de masse simple, puis de le fusionner à l'ensemble des voxels.

#### 5.2.3.1 Intégration d'une connaissance *a priori*

L'intégration de la connaissance *a priori* est réalisée comme suit : Soit  $\beta \in [0, 1]$  la part de croyance imprécise, affectée à l'hypothèse  $\{\omega_1, \omega_2\}$ , devant être transférée à l'hypothèse  $\{\omega_2\}$  correspondant à la lésion. Nous proposons de représenter cette connaissance par la fonction de masse simple suivante, possédant deux éléments focaux :

$$\begin{aligned} m_\beta(\{\omega_2\}) &= \beta \\ m_\beta(\Omega) &= 1 - \beta \end{aligned} \tag{5.15}$$

où  $\{\omega_2\}$  est le sous ensemble à renforcer. La combinaison de chaque voxel avec cette fonction de masse est ensuite effectuée en utilisant la règle de Dempster :

$$\mathcal{M}_{V_i}(\cdot) = M_{V_i}(\cdot) \oplus m_\beta(\cdot). \tag{5.16}$$

Cette combinaison permet de transférer une part des croyances de l'ensemble  $\{\omega_1, \omega_2\}$  vers le sous ensemble  $\{\omega_2\}$  correspondant à la lésion, en fonction de la valeur de  $\beta$ . Les masses de



croissance étant alors principalement réparties sur les hypothèses  $\{\omega_1\}$  et  $\{\omega_2\}$ , il résulte de ce transfert une réduction des imprécisions.

### 5.2.3.2 Calcul de la connaissance *a priori*

Pour notre application, nous avons choisi de calculer l'*a priori*,  $\beta$ , en fonction de deux mesures : le volume  $Vol$  de la tumeur et le contraste  $Cont$  entre la tumeur et le fond, mesurés à la suite d'EVEII. Nous noterons donc  $\beta(Vol, Cont)$  notre *a priori*, dont les paramètres sont mesurés comme suit.

1. Le contraste  $Cont$  est obtenu de la manière suivante :

$$Cont = \frac{\sum_{i=1}^N M_{V_i}(\{\omega_2\})I_{V_i}}{\sum_{i=1}^N M_{V_i}(\{\omega_1\})I_{V_i}}. \quad (5.17)$$

Il correspond au rapport entre la moyenne pondérée des intensités dans la lésion et la moyenne pondérée des intensités dans le fond. Comme la masse portant sur la disjonction  $\{\omega_1, \omega_2\}$  n'intervient pas dans le calcul du contraste, les données imprécises ne sont pas utilisées.

2. Le volume  $Vol$  est obtenu par seuillage :

$$Vol = \sum_{i=1}^N \delta_i \begin{cases} 1 & \text{si } M_{V_i}(\{\omega_2\}) > 0,5 \\ 0 & \text{sinon} \end{cases} \quad (5.18)$$

Il correspond à la somme des voxels dont la croyance vis-à-vis de  $\{\omega_2\}$  est supérieure à 0,5. Par la suite,  $Vol$  est multiplié par le volume du voxel afin d'être converti en mL. Cela permet de ne comptabiliser que les voxels dont on est certain de leur appartenance à la lésion. Notons que ce volume est différent du volume final de la lésion mesuré ( $Vol_m$ ).

Connaissant le contraste  $Cont$  et le volume  $Vol$  d'une lésion à la suite d'EVEII, nous proposons d'utiliser la fonction présentée Figure 5.6 afin de déterminer la valeur de  $\beta(Vol, Cont)$ . Cette fonction est apprise à partir de données fantômes. L'apprentissage sera présenté dans le prochain chapitre.

### 5.2.4 Prise de décision

Comme nous l'avons vu section 4.5, plusieurs stratégies sont possibles au niveau de la prise de décision. Nous pouvons ainsi choisir d'utiliser le maximum de crédibilité, de plausibilité ou encore le maximum de probabilité pignistique. Comme seulement deux classes sont considérées

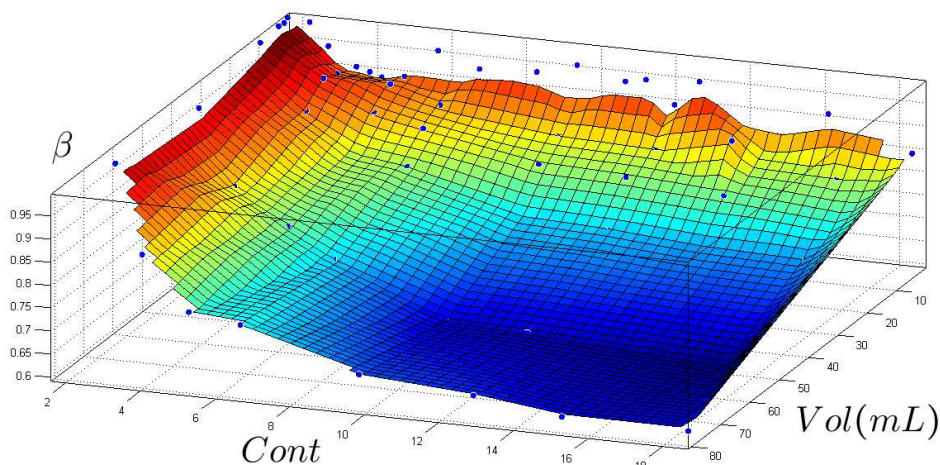


Figure 5.6 – Exemple de courbe présentant la fonction  $\beta(Cont, Vol) \in [0, 1]$ .

pour notre problème de segmentation, le choix d'une stratégie plutôt qu'une autre n'a pas d'influence pour la prise de décision. De plus, il résulte de notre processus de réduction de l'imprécision, que la masse portant sur la disjonction  $\{\omega_1, \omega_2\}$  est faible, d'où l'absence d'ambiguïté. Nous proposons cependant d'utiliser le maximum de plausibilité afin de déterminer à quelle classe chaque voxel appartient.

### 5.3 Segmentation multi-traceurs

Dans la précédente section, nous avons présenté une nouvelle méthode nommée EVEII, basée sur la théorie des fonctions de croyance, pour la segmentation d'images TEP. Elle a l'avantage de permettre la réduction de l'incertitude et de l'imprécision. Nous proposons à présent de reprendre cette méthode pour fusionner les images TEP au  $^{18}\text{FDG}$ , à la  $^{18}\text{FLT}$  et au  $^{18}\text{FMiso}$ . L'objectif est de segmenter les différentes régions afin d'aider le radiothérapeute à planifier le *dose painting*.

Tout d'abord, nous présentons le cadre de discernement que l'on se propose de définir pour segmenter l'ensemble des trois images TEP. Ensuite, nous présentons de quelle manière sont estimées les masses de croyance pour chacune des images TEP. Enfin, nous présentons leur fusion.

#### 5.3.1 Cadre de discernement

Pour la définition du cadre de discernement, il convient de rappeler que les classes retenues doivent être exclusives, c'est à dire que deux classes ne peuvent pas être assignées à un même objet. Par ailleurs, nous avons postulé que l'image de référence est l'image TEP au  $^{18}\text{FDG}$ , les

autres images ( $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$ ) correspondant à des sous-volumes à identifier par rapport au volume d'hyper-métabolisme glucidique. De ce fait, nous proposons les hypothèses suivantes pour notre cadre de discernement :

- $\{N\}$  correspond aux tissus Normaux par rapport au métabolisme glucidique.
- $\{M\}$  correspond aux tissus normoxiques sans prolifération cellulaire, mais présentant un hyper-métabolisme glucidique, c'est à dire sans hyper-fixation en  $^{18}\text{FMiso}$  et à la  $^{18}\text{FLT}$ , mais présentant une hyper-fixation en  $^{18}\text{FDG}$ .
- $\{P\}$  correspond aux tissus présentant un hyper-métabolisme glucidique associé à une importante prolifération cellulaire, c'est à dire sans hyper-fixation en  $^{18}\text{FMiso}$ , mais avec une hyper-fixation en  $^{18}\text{FDG}$  et à la  $^{18}\text{FLT}$ .
- $\{H\}$  correspond aux tissus présentant un hyper-métabolisme glucidique associé à une hypoxie, c'est à dire sans hyper-fixation à la  $^{18}\text{FLT}$ , mais avec une hyper-fixation en  $^{18}\text{FDG}$  et en  $^{18}\text{FMiso}$ .
- $\{F\}$  pour *Full uptake*, correspond aux tissus présentant à la fois un hyper-métabolisme glucidique, une importante prolifération cellulaire et une hypoxie, c'est à dire présentant une forte fixation avec les trois traceurs.

Ainsi, le cadre de discernement est donné par  $\Omega = \{N, M, P, H, F\}$ , où les cinq hypothèses sont exclusives. De ce fait,  $2^5 = 32$  hypothèses simples et multiples sont considérées dans le cadre de la théorie des fonctions de croyance :  $2^\Omega = \{\emptyset, \{N\}, \{M\}, \{P\}, \dots, \{N, M\}, \dots, \Omega\}$ .

### 5.3.2 Estimation des masses de croyance

Considérant séparément chacune des trois images, l'estimation des masses de croyance pour chaque voxel est réalisée par l'intermédiaire d'EVEII afin de réduire les incertitudes dues au bruit. Elle est suivie de la méthode proposée pour la réduction des imprécisions dues à l'effet de volume partiel. Nous avons ainsi :  $\mathcal{M}_{FDG, V_i}(\cdot)$ ,  $\mathcal{M}_{FLT, V_i}(\cdot)$  et  $\mathcal{M}_{FMiso, V_i}(\cdot)$  les masses de croyance correspondant respectivement aux traceurs  $^{18}\text{FDG}$ ,  $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$  pour un même voxel  $V_i$ . Ceci permet d'estimer pour chacune des images TEP les masses vis à vis de trois hypothèses, notées  $\{\omega_1\}$ ,  $\{\omega_2\}$  et  $\{\omega_1, \omega_2\}$ .

Étant donné le cadre de discernement considéré pour la fusion des images, nous proposons, en accord avec l'interprétation médicale, d'estimer pour chaque image les masses de croyance selon les trois hypothèses conformément au Tableau 5.1. Nous supposons ici qu'une faible fixation du  $^{18}\text{FDG}$  correspond à un tissu normal vis-à-vis du métabolisme glucidique, qu'une fixation élevée du  $^{18}\text{FDG}$  peut à la fois correspondre à une fixation élevée ou faible de la

	Faible fixation du traceur	Forte fixation du traceur	Ambiguïté
<b>Image</b>	$\{\omega_1\}$	$\{\omega_2\}$	$\{\omega_1, \omega_2\}$
$^{18}\text{FDG}$	$\{N\}$	$\{M, P, H, F\}$	$\{N, M, P, H, F\}$
$^{18}\text{FLT}$	$\{N, M, H\}$	$\{P, F\}$	$\{N, M, P, H, F\}$
$^{18}\text{FMiso}$	$\{N, M, P\}$	$\{H, F\}$	$\{N, M, P, H, F\}$

Tableau 5.1 – Hypothèses considérées pour chaque image en vue de les fusionner.

$^{18}\text{FLT}$  et du  $^{18}\text{FMiso}$ , et qu'une faible fixation de la  $^{18}\text{FLT}$  ou du  $^{18}\text{FMiso}$  ne conduit pas nécessairement à la présence d'un tissu normal.

Comme nous pouvons le constater dans le Tableau 5.1, la représentation choisie conduit à la présence d'ambiguïtés car la majorité des hypothèses considérées ont une cardinalité supérieure à 1. Une forte fixation du  $^{18}\text{FDG}$  est par exemple représentée par l'ensemble de quatre classes  $\{M, P, H, F\}$ . Comme nous l'avons vu section 5.3.1, on retrouve pour ces quatre classes la présence d'un hyper-métabolisme glucidique. L'ambiguïté provient du fait que l'on a aucune connaissance sur la présence d'une éventuelle prolifération cellulaire ou hypoxie avec cette seule modalité. Par opposition, une faible fixation du  $^{18}\text{FDG}$ , pris comme référence, témoigne sans ambiguïté de la présence d'un tissu normal vis-à-vis du métabolisme glucidique. Une forte fixation de la  $^{18}\text{FLT}$  conduit à la présence d'une hyper-prolifération cellulaire, représentée par la disjonction  $\{P, F\}$ . Ce traceur ne nous permet pas de trancher en faveur des classes  $P$  et  $F$  puisqu'il n'apporte aucune information au sujet de l'hypoxie. Par opposition, une faible fixation de la  $^{18}\text{FLT}$  est représentée par l'hypothèse  $\{N, M, H\}$ , et témoigne de la présence d'un tissu qui peut être normal ou non vis-à-vis du métabolisme glucidique, ou présentant une hypoxie. Enfin, l'ambiguïté constatée avec le  $^{18}\text{FMiso}$  est équivalente à l'ambiguïté observée avec la  $^{18}\text{FLT}$ .

### 5.3.3 Fusion des images TEP multi-traceurs

L'ensemble des images ayant le même cadre de discernement, leur fusion peut être effectuée. Nous proposons d'utiliser l'opérateur de combinaison conjonctif présenté section 4.3.1 sans normalisation.

$$\mathfrak{M}_{V_i}(\cdot) = \mathcal{M}_{FDG, V_i}(\cdot) \odot \mathcal{M}_{FLT, V_i}(\cdot) \odot \mathcal{M}_{FMiso, V_i}(\cdot). \quad (5.19)$$

Il permet de lever les imprécisions présentées Tableau 5.1 en tirant partie de la complémentarité des images. En effet, l'opérateur conjonctif permet de transférer la croyance sur les plus petits sous-ensembles.

Les sous-ensembles sur lesquels sont principalement réparties les croyances après fusion sont présentés Tableaux 5.2 et 5.3. L'hypothèse  $\{N, M, P, H, F\}$  n'est pas considérée afin de

	$\odot$	$\mathcal{M}_{FLT,V_i}$	
		$\{N, M, H\}$	$\{P, F\}$
$\mathcal{M}_{FMiso,V_i}$	$\{N, M, P\}$	$\{N, M\}$	$\{P\}$
	$\{H, F\}$	$\{H\}$	$\{F\}$

Tableau 5.2 – Hypothèses considérées suite à la fusion des images TEP à la  $^{18}FLT$  et au  $^{18}FMiso$  par l'opérateur de combinaison conjonctif.

	$\odot$	$\mathcal{M}_{FLT,V_i} \odot \mathcal{M}_{FMiso,V_i}$			
		$\{N, M\}$	$\{P\}$	$\{H\}$	$\{F\}$
$\mathcal{M}_{FDG,V_i}$	$\{N\}$	$\{N\}$	$\emptyset$	$\emptyset$	$\emptyset$
	$\{M, P, H, F\}$	$\{M\}$	$\{P\}$	$\{H\}$	$\{F\}$

Tableau 5.3 – Hypothèses considérées suite à la fusion des images TEP à la  $^{18}FLT$ , au  $^{18}FMiso$  et au  $^{18}FDG$  par l'opérateur de combinaison conjonctif.

faciliter la lecture du tableau. Notons que les masses portant sur cette hypothèse sont faibles étant donné notre processus de réduction des imprécisions dues à l'effet de volume partiel. Le Tableau 5.2 présente l'ensemble des hypothèses considérées à l'issue de la fusion des modalités  $^{18}FLT$  et  $^{18}FMiso$ . Nous pouvons remarquer que cette fusion permet principalement de distinguer les hypothèses  $P$ ,  $H$  et  $F$ . En appliquant ensuite la fusion avec la modalité  $^{18}FDG$ , les masses de croyance portent sur les hypothèses présentées Tableau 5.3. Comme nous pouvons le constater, ces hypothèses sont des singletons, témoignant de la réduction de l'imprécision à l'issue de la fusion. En outre, comme nous pouvons le constater, un conflit apparaît ( $\emptyset$ ). Ce dernier correspond à une forte fixation de la  $^{18}FLT$  et du  $^{18}FMiso$ , mais à une faible fixation du  $^{18}FDG$ . Le conflit correspond aux tissus sains présentant une forte prolifération cellulaire ou une hypoxie. Notons qu'aucun conflit ne serait apparu si nous avions envisagé, lors de la définition des hypothèses, qu'une forte fixation avec la  $^{18}FLT$  et le  $^{18}FMiso$  puisse également témoigner de la présence d'un tissu normal. Cependant, nous avons préféré écarter cette hypothèse de façon à faire ressortir ces conflits qu'il est intéressant de distinguer. D'un point de vue physiologique, certains tissus sains (moelle osseuse par exemple) présentent une importante prolifération cellulaire qui n'est pas accompagnée d'un hyper-métabolisme glucidique. La présence de l'imagerie TDM anatomique permet au radiothérapeute de facilement interpréter le conflit mis en évidence par notre méthode comme ne relevant pas d'une pathologie tumorale.

### 5.3.4 Prise de décision

La prise de décision, effectuée en dernier lieu, offre une segmentation multi-traceurs. Nous proposons d'utiliser le maximum de plausibilité. Cela permet de déterminer à quelle classe, parmi  $\{N\}$ ,  $\{M\}$ ,  $\{P\}$ ,  $\{H\}$ ,  $\{F\}$  et l'ensemble vide  $\emptyset$ , appartient chacun des voxels.

## 5.4 Conclusion

Dans ce chapitre, nous avons présenté notre méthode de segmentation d'images TEP, mono-traceur dans un premier temps, puis multi-traceurs dans un second temps. Notre méthode de segmentation mono-traceur a pour avantage principal de permettre la réduction de l'incertitude due au bruit et la modélisation de l'imprécision due à l'effet de volume partiel par fusion des informations de voisinage. La fusion est réalisée grâce aux opérateurs de la théorie des fonctions de croyance. En outre, nous proposons une méthode de réduction de l'imprécision s'appuyant sur un *a priori* ici appris sur des données TEP issues d'un fantôme physique simulant des hyper-fixations. Cette méthode permet d'améliorer la représentation des données, dans l'objectif soit de segmenter une image TEP mono-traceur, soit de fusionner un ensemble d'images TEP multi-traceurs.



# Chapitre 6

## Évaluation et expérimentation

### Sommaire

---

<b>6.1</b>	<b>Introduction</b>	<b>135</b>
<b>6.2</b>	<b>Évaluation d'EVEII sur des images simulées</b>	<b>136</b>
6.2.1	Matériel et méthodes	136
6.2.2	Résultats	141
6.2.3	Discussion	146
6.2.4	Conclusion	148
<b>6.3</b>	<b>Évaluation d'EVEII sur des images de fantôme TEP</b>	<b>149</b>
6.3.1	Paramétrage de la méthode	149
6.3.2	Fantôme 1	152
6.3.3	Fantôme 2	158
6.3.4	Conclusion	166
<b>6.4</b>	<b>Application de la méthode aux images TEP multi-traceurs</b>	<b>167</b>
6.4.1	Matériel et méthodes	167
6.4.2	Résultats	170
6.4.3	Discussion	174
<b>6.5</b>	<b>Conclusion</b>	<b>175</b>

---

### 6.1 Introduction

Ce chapitre est dédié à l'évaluation des propositions algorithmiques faites dans le chapitre précédent. Tout d'abord, notre méthode de segmentation d'images mono-traceurs est évaluée sur des images simulées, en comparaison avec d'autres méthodes de la littérature proposées pour la segmentation de données présentant des imperfections. Ensuite, elle est évaluée sur des images TEP de fantômes physiques beaucoup plus proches de la vérité terrain. Enfin, l'évaluation de la méthode de segmentation d'images mono-traceur et multi-traceurs est réalisée sur des images patients.



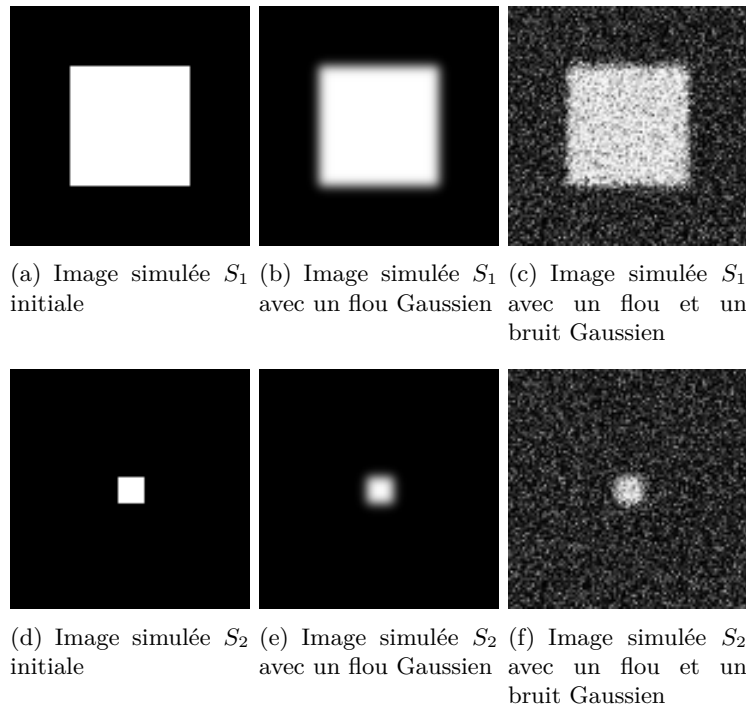


Figure 6.1 – Construction des images simulées présentant de l’effet de volume partiel et du bruit. (a) et (d) sont les deux images simulées initiales. (b) et (e) sont les deux images simulées (a) et (d) dont les contours ont été altérés par l’intermédiaire d’un filtre Gaussien de FWHM=5 pixels. (c) et (f) sont les deux images simulées (b) et (e) avec adjonction d’un bruit Gaussien d’écart type  $\sigma = 0,2$ , correspondant à un RSB de 5.

Notons que les méthodes proposées, ainsi que celles de la littérature, utilisées à titre comparatif tout au long du chapitre, ont été implémentées dans le langage de programmation *JAVA*, pour être ensuite intégrées sous forme de *plugin* au logiciel de traitement d’images *ImageJ* [Abramoff *et al.*, 2004].


## 6.2 Évaluation d’EVEII sur des images simulées

Dans cette section, nous évaluons notre méthode EVEII en la comparant à des méthodes de segmentation mono-traceur déjà proposées dans la littérature [Bezdek, 1981; Bloch, 2008; Masson et Dencœux, 2008; Makni *et al.*, 2012]. Cette évaluation a été réalisée sur deux images simulées ainsi que sur deux séries d’images simulées.

### 6.2.1 Matériel et méthodes

#### 6.2.1.1 Images simulées

Dans un premier temps, deux images simulées notées  $S_1$  et  $S_2$ , de taille  $100 \times 100$  pixels, contenant un objet carré ont été utilisées. La différence entre les deux images concerne la taille



(a) Image simulée  $S_3(8,5 ; 1,5)$  (b) Image simulée  $S_3(7,5 ; 2,5)$  (c) Image simulée  $S_3(6,5 ; 3,5)$  (d) Image simulée  $S_3(5,5 ; 4,5)$  (e) Image simulée  $S_3(4,5 ; 5,5)$

Figure 6.2 – Cinq images simulées parmi la série  $S_3(\text{FWHM} ; \text{RSB})$ .

du carré. Il fait  $50 \times 50$  pixels pour  $S_1$  et  $10 \times 10$  pour  $S_2$  comme illustré Figures 6.1(a) et (d). Les deux images sont représentées par deux classes, avec pour cadre de discernement  $\Omega = \{\omega_1, \omega_2\}$ . Le fond et le carré ont respectivement pour valeur 0 et 1.

Par ailleurs, la présence d'effet de volume partiel et de bruit a été ajouté pour chaque image. L'effet de volume partiel est simulé par une transition floue obtenue par convolution de l'image avec un filtre Gaussien de FWHM égal à 5 pixels (voir Figures 6.1(b) et (e)). Le bruit est ensuite ajouté de manière à obtenir un Rapport Signal-sur-Bruit (RSB) de 5. Ce dernier est également Gaussien avec pour écart type  $\sigma = 0,2$  (voir Figures 6.1(c) et (f)). Notons qu'après adjonction de la transition floue et du bruit, le second carré  $S_2$  est très dégradé.

Dans un second temps, une série d'images simulées, notée  $S_3(\text{FWHM} ; \text{RSB})$ , a été simulée. L'ensemble des images correspond à l'image  $S_1$ , avec en premier lieu une transition floue réalisée par l'intermédiaire du filtre Gaussien de FWHM variant de 8,5 à 4,1 par pas de -0,2. En second lieu, un bruit Gaussien est associé à chacune des images de sorte que le rapport signal-sur-bruit varie de  $\text{RSB} = 1,5$  à 5,9 par pas de 0,2. Ainsi :

- pour une transition floue obtenu avec une FWHM de 8,5, le RSB vaut 1,5,
- pour une transition floue obtenu avec une FWHM de 8,3, le RSB vaut 1,7,

et ainsi de suite jusqu'à l'image  $S_3(4,1 ; 5,9)$  correspondant à une transition floue de FWHM 4,1, et un RSB de 5,9. Au total, la série  $S_3(\text{FWHM} ; \text{RSB})$  compte 22 images dont cinq sont présentées Figure 6.2.

Enfin, une seconde série d'images, notée  $S_4(\text{FWHM} ; \text{RSB})$ , a été simulée. Le protocole de construction des images est le même qu'avec  $S_3(\text{FWHM} ; \text{RSB})$ , mais l'ensemble des images correspond à l'image  $S_2$ .

Chaque image simulée a un objectif différent. L'image  $S_1$  a pour but d'apprécier le résultat d'estimation des croyances, offert par l'ensemble des méthodes qui seront évaluées, face à la présence d'une transition floue entre les régions et de bruit. L'image  $S_2$  permet de plus d'apprécier le comportement des méthodes face à une distribution des données inégale entre les classes.

En effet, le second carré représente seulement 1 % des données de l'image. Les séries d'images  $S_3$  et  $S_4$  ont pour objectif d'évaluer les résultats de segmentation, sur les images simulées  $S_1$  et  $S_2$  respectivement, mais vis-à-vis de différents rapports signal-sur-bruit.

### 6.2.1.2 Méthodes évaluées

Notre méthode est appliquée sur l'ensemble des images simulées. Dans un premier temps, elle est appliquée à partir d'une distribution de masse donnée par l'algorithme FCM (méthode EVEII<sub>1</sub>). Dans un second temps, elle est appliquée à partir d'une distribution de masse donnée par l'algorithme FCM intégrant l'étape de combinaison disjunctive des informations de voisinage dans son processus itératif (méthode EVEII<sub>3</sub>).

Nous proposons de comparer ces deux variantes de la méthode EVEII à cinq autres méthodes proposées dans la littérature. Il s'agit de :

- L'algorithme FCM [Bezdek, 1981].
- La méthode introduite dans [Bloch, 2008], et notée MORPHO, utilisant des opérateurs de morphologie mathématique flous pour transférer une partie de la croyance sur les hypothèses multiples. Cette méthode a été introduite section 4.4.3.2 et est appliquée à l'issue de la modélisation initiale donnée par l'algorithme FCM.
- L'algorithme ECM, extension de l'algorithme FCM introduite dans [Masson et Denceux, 2008] et présenté section 4.4.2.2.
- L'algorithme ECM suivi d'une combinaison conjonctive des informations de voisinage. Elle est notée ECM<sub>c</sub>.
- L'algorithme MECM introduit dans [Makni *et al.*, 2012] et intégrant au sein de l'algorithme ECM la combinaison conjonctive des informations de voisinage.

Le paramètre  $m$  est fixé à 2 pour l'algorithme FCM, ainsi que pour EVEII<sub>3</sub>. Nous avons fixé  $\alpha = 1$ ,  $\beta = 2$  et  $\delta = 1$  pour les algorithmes ECM et MECM. Notons que la faible valeur de  $\delta$  permet d'éviter d'avoir des *outliers*. Pour l'érosion floue dans la méthode MORPHO, la *t-norme* minimum a été utilisée [Bloch, 1996a]. Enfin, pour toutes les méthodes tenant compte du voisinage, l'élément structurant est un filtre Gaussien de FWHM égal à 5 pixels.

### 6.2.1.3 Évaluation

Dans un premier temps, une interprétation visuelle des masses de croyance obtenues suite à l'étape d'estimation, pour chacune des méthodes, a été réalisée. À cet effet, des images paramétriques de  $S_1$  et  $S_2$ , correspondant aux fonctions de masses vis-à-vis des hypothèses

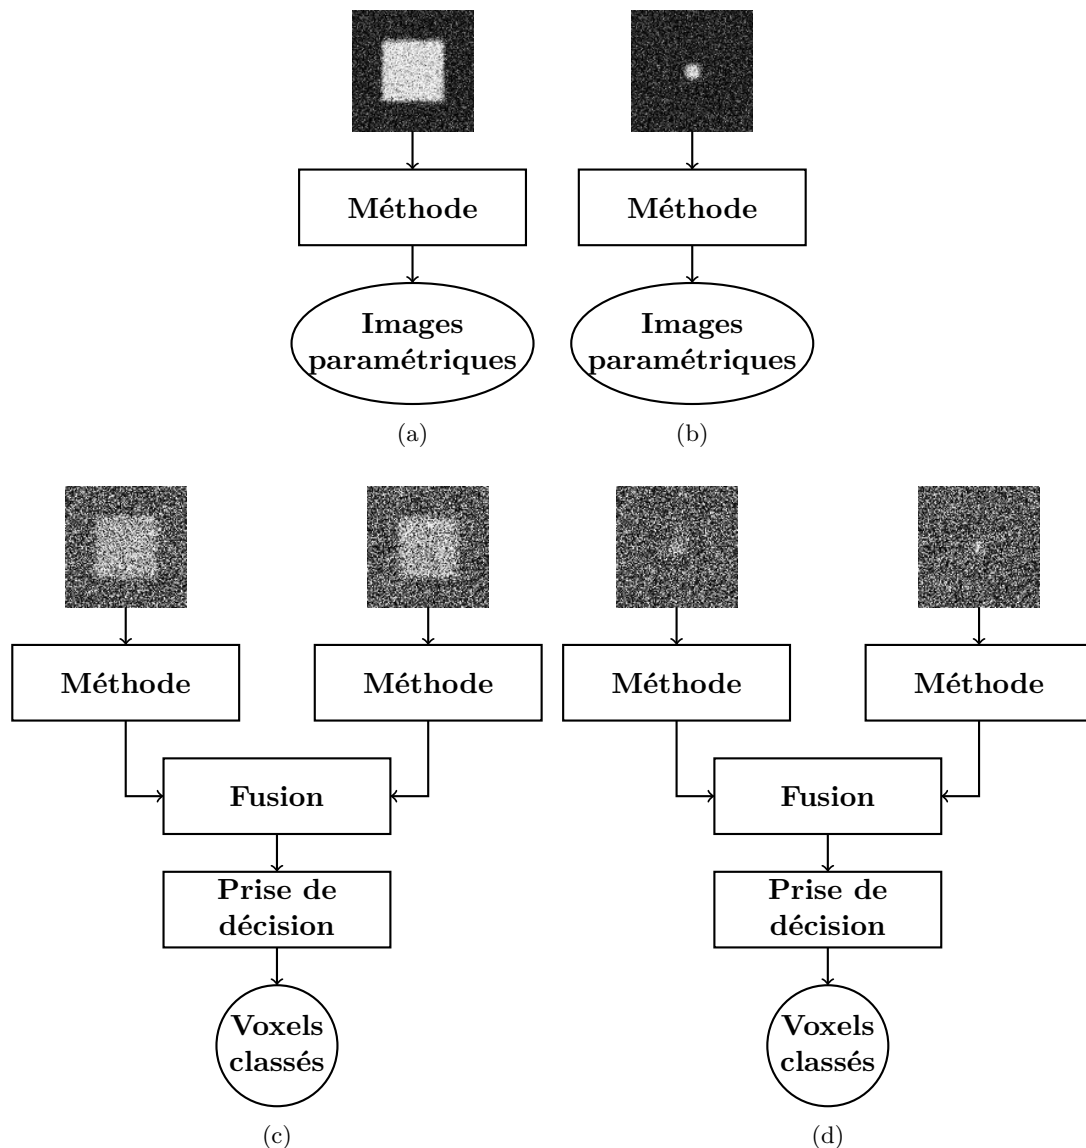


Figure 6.3 – Schémas illustrant les quatre processus mis en place pour l'évaluation des sept méthodes étudiées : FCM, EVEII<sub>1</sub>, EVEII<sub>3</sub>, MORPHO, ECM, ECM<sub>c</sub> et MECM. (a), (b), (c) et (d) illustrent les processus utilisés pour les images  $S_1$  et  $S_2$ , et les séries  $S_3$  et  $S_4$  respectivement.

$\{\omega_1\}$ ,  $\{\omega_2\}$  et  $\{\omega_1, \omega_2\}$  ont été créées.  $\{\omega_1\}$  et  $\{\omega_2\}$  correspondent respectivement à l'hypothèse d'être dans le fond et dans le carré, et  $\{\omega_1, \omega_2\}$  correspond à l'hypothèse d'ignorance.

Dans un second temps, une analyse des performances a été réalisée sur les séries d'images  $S_3$ (FWHM ; RSB) et  $S_4$ (FWHM ; RSB) pour chaque méthode. À cet effet, chaque méthode a été appliquée sur deux répliques de chaque série d'images  $S_3$ (FWHM ; RSB) et  $S_4$ (FWHM ; RSB), et les résultats d'estimation sur les deux répliques ont ensuite été fusionnés en utilisant la règle conjonctive de Dempster (voir Figure 6.3(c) et (d)). Nous proposons d'appliquer chacune des méthodes sur deux répliques pour chaque série du fait que les méthodes MORPHO et ECM n'aient pas été introduites pour la réduction des incertitudes, mais pour




Figure 6.4 – Modélisation des imperfections sur l'image  $S_1$  présentée en (a) en utilisant notre méthode EVEII et cinq autres méthodes pour comparaison. (b) est le résultat en utilisant l'algorithme FCM. (c), (d) and (e) sont les résultats en utilisant notre méthode EVEII avec et sans estimation initiale de croyances. (c) est obtenu en appliquant la combinaison disjonctive des informations de voisinage après l'algorithme FCM. (d) est le résultat obtenu en appliquant ensuite la combinaison conjonctive des informations de voisinage. (e) est le résultat en appliquant tout d'abord la combinaison disjonctive au sein de l'algorithme FCM et ensuite la combinaison conjonctive. (f), (g) et (i) sont les résultats en utilisant respectivement les méthodes proposées dans [Bloch, 2008], [Masson et Dencœux, 2008] et [Makni *et al.*, 2012], où MORPHO est obtenu à l'issue de l'algorithme FCM. (h) est le résultat de l'algorithme ECM suivi de la combinaison conjonctive des informations de voisinage.

leur modélisation sur les disjonctions. La fusion des deux images a pour but de réduire les incertitudes, et de permettre de réaliser des comparaisons. Ainsi, pour chaque méthode, une série d'images paramétriques est obtenue après fusion. Après l'étape de prise de décision (maximum de plausibilité) l'analyse des performances de chaque méthode est réalisée par mesure du taux de bonne reconnaissance (taux de pixels correctement étiquetés). Cette mesure est donnée par :

$$T_r = \frac{1}{REP} \sum_{rep=0}^{REP} \frac{\sum_{i=1}^N \delta(C_m(V_i), C_r(V_i))}{N}, \quad (6.1)$$

où  $C_m(V_i)$  et  $C_r(V_i)$  sont respectivement la classe mesurée et la classe réelle pour un voxel  $V_i$ , et où  $\delta$  est la fonction de Kronecker :  $\delta(x, y) = \{1 \text{ si } x = y, 0 \text{ sinon}\}$ . Rappelons que  $N$  est égal à la quantité totale de pixels dans l'image. Du fait de la présence de bruit dans les images, pour garantir une bonne mesure statistique de  $T_r$ , le taux de bonne reconnaissance est calculé en répétant  $REP = 20$  fois l'ensemble du processus.  $T_r$  correspond donc à un taux moyen.

### 6.2.2 Résultats

Les images paramétriques de l'image simulée  $S_1$  correspondant aux fonctions de croyance vis-à-vis des hypothèses  $\{\omega_1\}$ ,  $\{\omega_2\}$  et  $\{\omega_1, \omega_2\}$  sont données Figure 6.4 pour chacune des méthodes. Le résultat obtenu en utilisant l'algorithme FCM est tout d'abord présenté à la Figure 6.4(b). Comme nous l'avons utilisé afin d'assigner des masses de croyance sur les singletons, la disjonction  $\{\omega_1, \omega_2\}$  pour la modélisation des imprécisions n'a pas été considérée. Les méthodes EVEII<sub>1</sub> et MORPHO, modélisant la croyance à partir de la distribution offerte par l'algorithme FCM, sont ensuite comparées. La première étape de notre méthode est notée EVEII<sub>1d</sub> et consiste en la combinaison disjonctive des informations de voisinage ( $\odot_{\Phi}$ ). À l'issue de cette étape, comme nous pouvons le voir Figure 6.4(c), les masses de croyance sont réparties sur les trois hypothèses  $\{\omega_1\}$ ,  $\{\omega_2\}$  et  $\{\omega_1, \omega_2\}$ . La croyance des pixels dont le voisinage est ambigu porte principalement sur l'hypothèse  $\{\omega_1, \omega_2\}$ . En appliquant ensuite la combinaison conjonctive des informations de voisinage ( $\odot_{\Phi}$ ), nous obtenons la distribution présentée Figure (d) notée EVEII<sub>1c</sub>. La méthode fournit des croyances élevées en faveur de  $\{\omega_1\}$  et  $\{\omega_2\}$  au sein des régions, traduisant la réduction des incertitudes dues au bruit. Aux transitions entre les régions, les croyances portent principalement sur l'hypothèse  $\{\omega_1, \omega_2\}$ , soulignant l'imprécision. Par comparaison, MORPHO permet d'affecter de fortes masses de croyance à l'hypothèse multiple  $\{\omega_1, \omega_2\}$  pour l'ensemble des informations ambiguës (Figure 6.4(f)). Notre méthode EVEII<sub>3</sub> est présentée Figure 6.4(e). L'utilisation de la combinaison disjonctive au sein de l'algorithme FCM n'induit pas de net changement comparée au résultat donné par EVEII<sub>1c</sub>




Figure 6.5 – Modélisation des imperfections sur l'image  $S_2$  présentée en (a) en utilisant notre méthode EVEII et cinq autres méthodes pour comparaison. (b) est le résultat en utilisant l'algorithme FCM. (c), (d) and (e) sont les résultats en utilisant notre méthode EVEII avec et sans estimation initiale de croyances. (c) est obtenu en appliquant la combinaison disjonctive des informations de voisinage après l'algorithme FCM. (d) est le résultat obtenu en appliquant ensuite la combinaison conjonctive des informations de voisinage. (e) est le résultat en appliquant tout d'abord la combinaison disjonctive au sein de l'algorithme FCM et ensuite la combinaison conjonctive. (f), (g) et (i) sont les résultats en utilisant respectivement les méthodes proposées dans [Bloch, 2008], [Masson et Dencœux, 2008] et [Makni *et al.*, 2012], où MORPHO est obtenu à l'issue de l'algorithme FCM. (h) est le résultat de l'algorithme ECM suivi de la combinaison conjonctive des informations de voisinage.

(comparaison des Figures 6.4(d) et (e)). En comparant EVEII<sub>3</sub> à l'algorithme ECM (Figures 6.4(e) et (g)), nous remarquons que ECM considère toutes les données entachées d'ambiguïtés sur la disjonction alors qu'EVEII<sub>3</sub> ne considère que les informations à la transition entre les régions sur la disjonction. Ce résultat montre que l'utilisation du voisinage, telle que proposée, permet de modéliser de manière différenciée les incertitudes et les imprécisions. Le résultat en appliquant la combinaison conjonctive des informations de voisinage à l'issue de l'algorithme ECM est donné à la Figure 6.4(h). Ces images paramétriques sont très voisines de celles obtenues avec MECM effectuant la combinaison conjonctive au sein de l'algorithme ECM (Figure 6.4(g)). Pour ces deux méthodes, les masses de croyance affectées à la disjonction sont très faibles.

Le même type d'images paramétriques est donné Figure 6.5 pour l'image simulée  $S_2$ . Le point important à remarquer est que, pour les données du fond qui sont bruitées, les algorithmes FCM et ECM estiment des masses de croyance favorisant largement l'hypothèse  $\{\omega_2\}$  (voir Figures 6.5(b) et (g)). Comme nous pouvons le constater, ce phénomène est également observé en utilisant la méthode ECM<sub>c</sub> (Figure 6.5(h)). En utilisant EVEII<sub>1</sub> ou MORPHO, nous pouvons remarquer que les informations du fond sont majoritairement représentées sur la disjonction, indiquant qu'elles sont ambiguës. Les résultats obtenus à partir des méthodes MECM et EVEII<sub>3</sub> sont données aux Figures 6.5(i) et (e). Avec MECM, quelques données très bruitées du fond ont une forte masse de croyance vis à vis  $\{\omega_2\}$ . Avec EVEII<sub>3</sub>, les masses élevées sur l'hypothèse  $\{\omega_1, \omega_2\}$  concernent principalement les pixels aux transitions entre les régions.

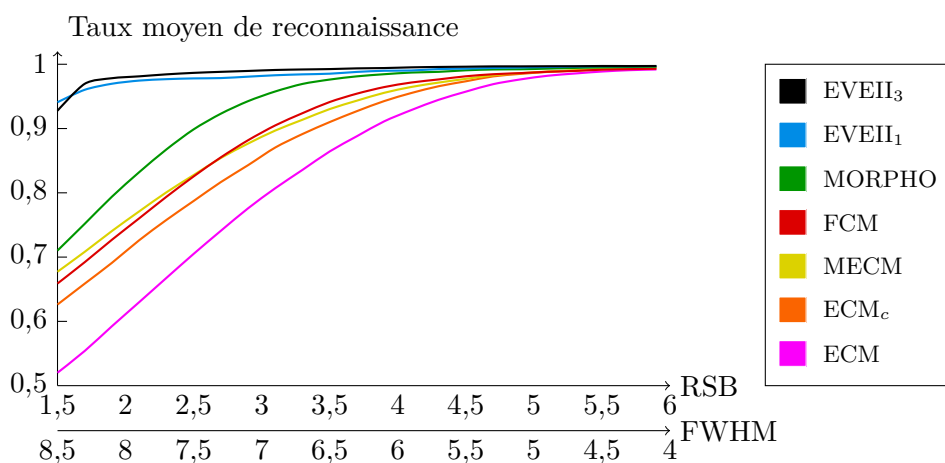


Figure 6.6 – Présentation des taux de reconnaissance en fonction de différentes valeurs de FWHM et RSB sur la série d'images simulées  $S_3$  (FWHM ; RSB) en utilisant sept méthodes. De bas en haut, en fonction des performances : l'algorithme ECM [Masson et Dencoux, 2008], ECM suivi de la combinaison conjonctive des informations de voisinage (ECM<sub>c</sub>), la méthode MECM [Makni *et al.*, 2012], l'algorithme FCM, la méthode MORPHO proposée dans [Bloch, 2008], et les deux variantes de notre méthode EVEII.



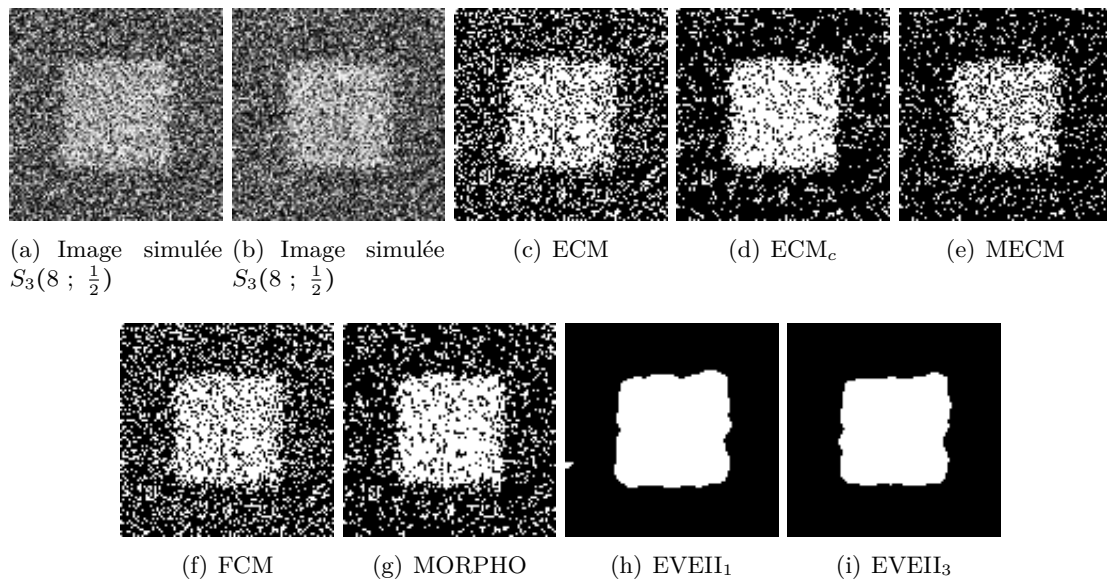


Figure 6.7 – Résultat de la segmentation de l'image  $S_3(8 ; \frac{1}{2})$  pour l'ensemble des méthodes.

La Figure 6.6 donne le taux de reconnaissance  $T_r$  moyen ( $n = 20$  reproductions) sur les 22 images de  $S_3(\text{FWHM} ; \text{RSB})$  pour les sept méthodes de classification évaluées. Pour faciliter l'interprétation des résultats de chaque méthode, les taux moyens sont représentés sous forme de courbe. Comme nous pouvons le voir, EVEII<sub>1</sub> et EVEII<sub>3</sub> donnent les meilleurs résultats, avec un taux de reconnaissance supérieur à 90% pour l'ensemble de la série. De plus, lorsque la combinaison disjonctive est intégrée dans l'algorithme FCM, les performances sont légèrement

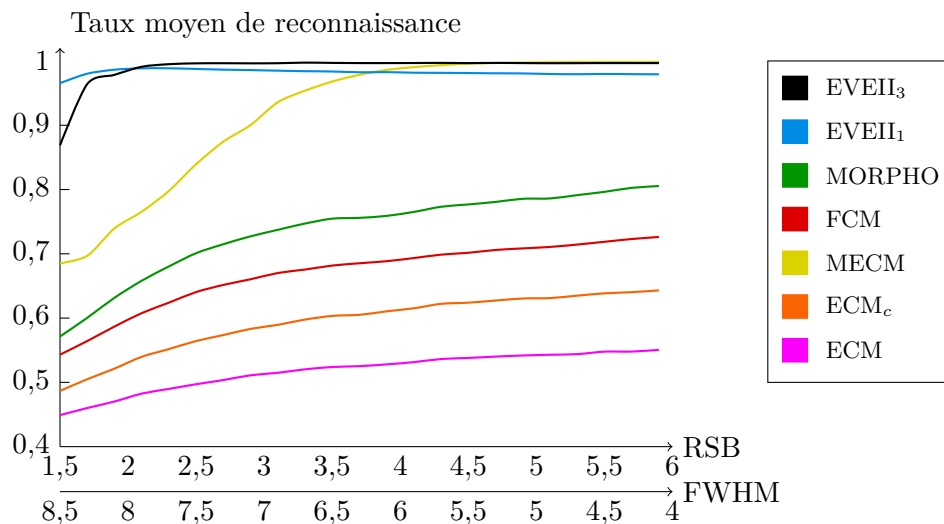


Figure 6.8 – Présentation des taux de reconnaissance en fonction de différentes valeurs de FWHM et RSB sur la série d'images simulées  $S_4(\text{FWHM} ; \text{RSB})$  en utilisant sept méthodes. De bas en haut, en fonction des performances : l'algorithme ECM [Masson et Dencœux, 2008], ECM suivi de la combinaison conjonctive des informations de voisinage (ECM<sub>c</sub>), la méthode MECM [Makni *et al.*, 2012], l'algorithme FCM, la méthode MORPHO proposée dans [Bloch, 2008], et les deux variantes de notre méthode EVEII.




Figure 6.9 – Résultat de la segmentation de l'image  $S_4(8 ; \frac{1}{2})$  pour l'ensemble des méthodes.

améliorées (EVEII<sub>3</sub> *vs.* EVEII<sub>1</sub>) à partir de RSB = 1,7 et FWHM = 8,3. Afin d'illustrer cette bonne performance de la méthode pour les images très dégradées, le résultat de la segmentation pour l'image  $S_3(8 ; \frac{1}{2})$  est présenté Figure 6.7 pour l'ensemble des méthodes. Comme nous pouvons le voir, seules les méthodes EVEII<sub>1</sub> et EVEII<sub>3</sub> permettent d'éliminer le bruit. En outre, comme nous pouvons le voir, l'algorithme FCM donne de meilleurs résultats qu'ECM. L'utilisation de l'information de voisinage (avec les autres méthodes) contribue en l'amélioration des taux de reconnaissance. En effet, il permet dans ECM<sub>c</sub> et MECM d'augmenter le taux de reconnaissance apporté par l'algorithme ECM. Dans MORPHO et EVEII<sub>1</sub>, il permet d'augmenter le taux de reconnaissance apporté par l'algorithme FCM.

Les résultats, pour les 22 images de la série  $S_4(\text{FWHM} ; \text{RSB})$  sont présentés Figure 6.8. Comme nous pouvons le voir, EVEII<sub>1</sub> et EVEII<sub>3</sub> donnent encore une fois les meilleurs résultats. Les méthodes ECM, ECM<sub>c</sub>, FCM et MORPHO donnent pour l'ensemble de la série de faibles performances, avec un taux de reconnaissance inférieur à 80 %. La méthode MECM donne de faibles performances pour une bruit RSB < 4 et une FWHM > 6. En revanche, pour un bruit RSB > 4 et une FWHM < 6, la méthode offre des performances équivalentes à EVEII<sub>3</sub>, avec un taux de reconnaissance proche de 100 %. Enfin, EVEII<sub>1</sub> affiche un comportement surprenant, avec un taux de reconnaissance élevé pour l'ensemble de la série, mais qui décroît légèrement au fur et à mesure que le bruit diminue. Les bonnes performances des méthodes sont illustrées Figure 6.7 pour l'image de la série  $S_4(\text{FWHM} ; \text{RSB})$  avec FWHM = 8 et RSB = 2. Seules les méthodes EVEII<sub>1</sub> et EVEII<sub>3</sub> permettent, une fois de plus, d'éliminer le bruit.

### 6.2.3 Discussion

Cette première évaluation d'EVEII a porté sur des données simulées en comparaison avec d'autres méthodes proposées dans la littérature pour la segmentation des données présentant des imperfections. Pour les données simulées, nous nous sommes attachés à y incorporer une transition floue entre les régions, ainsi qu'un bruit important, comme cela est le cas sur les images TEP cliniques. L'évaluation a dans un premier temps porté sur l'analyse de la répartition des masses de croyance vis-à-vis des hypothèses  $\{\omega_1\}$ ,  $\{\omega_2\}$  et  $\{\omega_1, \omega_2\}$  sous forme d'images paramétriques. L'analyse permet d'illustrer le mécanisme de répartition des masses pour les différentes méthodes proposées et d'observer ainsi le fonctionnement des algorithmes dans la prise en charge des imperfections. Dans un second temps, l'évaluation a porté sur la quantification du taux de bonne reconnaissance.

Sur l'image  $S_1$ , nous avons pu remarquer que l'algorithme FCM, tel qu'il a été utilisé, ne permet pas de considérer l'hypothèse  $\{\omega_1, \omega_2\}$ , ce qui conduit à une faible modélisation des imperfections. En appliquant notre méthode à partir de l'estimation offerte par l'algorithme FCM (méthode EVEII<sub>1c</sub>), nous avons pu remarquer qu'elle permet de réduire les incertitudes dues au bruit au sein des régions (fortes masses de croyance affectées aux singletons), et également de modéliser l'effet de volume partiel aux transitions entre les régions (fortes masses de croyance affectées à la disjonction). Par comparaison, MORPHO considère à la fois le bruit et l'effet de volume partiel comme des imprécisions car les voxels sujets à ces deux imperfections ont leur croyance portant sur la disjonction. Grâce à la combinaison conjonctive des informations de voisinage, notre méthode a l'avantage de réduire le bruit et de considérer seulement les informations imprécises, dues à l'effet de volume partiel, sur la disjonction. L'utilisation de la combinaison disjonctive au sein de l'algorithme FCM (EVEII<sub>3</sub>) n'induit pas de nette amélioration sur l'image  $S_1$ , comparée au résultat donné par EVEII<sub>1c</sub>. En comparant EVEII<sub>3</sub> à l'algorithme ECM, nous avons pu remarquer que ECM considère à la fois les incertitudes et les imprécisions sur la disjonction, alors qu'EVEII<sub>3</sub> les considère de manière différenciée grâce à l'utilisation du contexte spatial. Le résultat, en appliquant la combinaison conjonctive des informations de voisinage à l'issue de l'algorithme ECM (méthode ECM<sub>c</sub>), est similaire au résultat donné par MECM, effectuant la combinaison conjonctive au sein de l'algorithme ECM. Pour ces méthodes, de faibles masses de croyance sont affectées à la disjonction. Ceci est dû au fait que la combinaison conjonctive permet de réduire les incertitudes dues au bruit, mais également les imprécisions dues à l'effet de volume partiel. Rappelons que l'effet de volume partiel est principalement présent à la transition entre les régions dans les données images, et

qu'il correspond à un manque de connaissance qui devrait principalement être représenté sur la disjonction de notre point de vue.

$S_2$  a permis d'observer le comportement des méthodes pour la modélisation des imperfections sur une image présentant une distribution des données inégale entre les classes (peu d'information dans la classe correspondant au carré :  $10 \times 10$  pixels parmi  $100 \times 100$ ). On peut remarquer que les algorithmes FCM et ECM donnent une modélisation médiocre des croyances. Les masses de croyance pour les données bruitées dans le fond favorisent l'hypothèse  $\{\omega_2\}$  alors qu'elles devraient être élevées en faveur de l'hypothèse  $\{\omega_1\}$ . Cela vient du fait que la quantité d'information bruitée dans le fond est beaucoup plus importante par rapport à celle contenue dans le carré, conduisant à une estimation biaisée des centroïdes des classes. Comme nous avons pu le constater, il n'y a pas ou peu d'amélioration en utilisant les méthodes EVEII<sub>1</sub>, MORPHO et ECM<sub>c</sub> par rapport aux algorithmes FCM et ECM. Le moyen pour améliorer l'estimation est d'exclure les données incertaines et imprécises lors du calcul des centroïdes des classes au sein du processus itératif d'estimation des croyances. En effet, les meilleurs résultats sont observés avec MECM et EVEII<sub>3</sub>. Ces deux méthodes sont donc robustes à l'inégale distribution des données entre les classes. La différence entre ces deux méthodes est que, l'une réduit à la fois l'incertitude et l'imprécision avant de mettre à jour les centroïdes (MECM), l'autre n'utilise ni les données incertaines, ni les données imprécises, pour la mise à jour des centroïdes, et réduit les incertitudes par la suite (EVEII<sub>3</sub>). De plus, comme nous pouvons le constater, les pixels sujets à un bruit important sont mieux modélisés en utilisant EVEII<sub>3</sub>, ceci est dû à la fusion des informations de voisinage par l'opérateur de combinaison disjonctif pour transférer les données ambiguës sur la disjonction.

Lors de l'étude quantitative sur la série  $S_3$ , nous avons tout d'abord remarqué qu'EVEII<sub>1</sub> et EVEII<sub>3</sub> donnent les meilleurs taux de reconnaissance, et ce de façon d'autant plus nette que le bruit dans les images est important, ainsi que la transition floue. Les résultats sont légèrement meilleurs avec EVEII<sub>3</sub> à partir de  $RSB = 1,7$  et  $FWHM = 8,3$ . Ceci est dû à la robustesse d'EVEII<sub>3</sub> face à l'inégale distribution des données entre les classes comme nous venons de le voir. Nous avons de plus remarqué que l'algorithme FCM donne de meilleurs résultats que ECM en terme de taux de bonne reconnaissance. Ceci est également dû à la plus grande sensibilité de l'algorithme ECM à l'inégale distribution des données entre les classes. Comme nous pouvons l'observer sur la Figure 6.4(g) présentant l'estimation des masses avec l'algorithme ECM, les données bruitées dans le carré sont moins représentées sur la disjonction que les données bruitées dans le fond alors qu'elles sont en proportion égale dans les deux régions. Ce phénomène n'est pas observé avec l'algorithme FCM (voir Figure 6.4(b)), ce qui témoigne d'une moins bonne

estimation des centroïdes en utilisant l'algorithme ECM. Enfin, l'utilisation de l'information de voisinage contribue en l'amélioration des taux de reconnaissance. En effet, il permet pour l'ensemble des autres méthodes d'augmenter le taux de bonne reconnaissance. Ceci explique les meilleures performances de  $ECM_c$  et MECM par rapport à ECM, ainsi que MORPHO et EVEII par rapport à FCM.

Lors de l'étude quantitative sur la série  $S_4$ , nous avons remarqué qu'EVEII<sub>1</sub>, EVEII<sub>3</sub> et MECM donnent les meilleurs taux de reconnaissance à partir de  $RSB = 4$  et  $FWHM = 6$ . À partir de  $RSB = 2,5$  et  $FWHM = 7,5$  seuls EVEII<sub>1</sub> et EVEII<sub>3</sub> donnent de bon taux de reconnaissance. MECM est donc moins robuste face au bruit. En deçà de  $RSB = 2,5$  et  $FWHM = 7,5$ , les performances d'EVEII<sub>3</sub> sont dégradées. Cette faible performance, que l'on retrouvait avec la série  $S_3$ , mais qui est encore plus marquée ici, est due à une mauvaise estimation des centroïdes des classes pour quelques images parmi les 20 répliques. En effet, les taux de reconnaissances avoisinent 98 % pour la majeure partie des répliques, mais varient autour de 60 % pour quelques unes d'entre elles. Ainsi, lorsque le bruit est trop important, il peut arriver que les performances d'EVEII<sub>3</sub> chutent, ceci étant dû à une incapacité d'EVEII<sub>3</sub> à détecter les données certaines et précises pour la mise à jour des centroïdes des classes dans des conditions très dégradées. EVEII<sub>1</sub> offre globalement de bonnes performances, ce qui est contradictoire par rapport à la discussion que nous avons eu au sujet de l'image  $S_2$ . En effet, bien qu'EVEII<sub>1</sub> offre une mauvaise modélisation de  $S_2$  (voir Figure 6.5(d)), le fond et le carré sont relativement bien détectés après la maximisation des plausibilités (voir Figure 6.9(h)). En outre, nous pouvons remarquer que les taux de bonne reconnaissance avec EVEII<sub>1</sub> sont plus faibles au fur et à mesure que le bruit diminue. Ce phénomène est dû à la mauvaise estimation des centroïdes en présence de données inégalement réparties entre les classes. La présence d'un fort bruit conduit en une répartition uniforme de l'intensité des pixels sur l'histogramme de l'image et donc en l'estompement de l'inégale répartition des données entre les classes, d'où les bonnes performances d'EVEII<sub>1</sub> lorsque les images sont dégradées.

#### 6.2.4 Conclusion

Dans cette section, nous avons procédé à une analyse du comportement de notre méthode EVEII pour l'estimation des masses de croyance à visée de segmentation d'images correspondant à des simulations numériques. Comparée à cinq méthodes de la littérature utilisant la théorie des fonctions de croyance, les résultats ont montré que notre méthode offre une bonne estimation des croyances dans le contexte d'images fortement bruitées et avec une transition floue importante entre régions. En effet, nous avons pu voir qu'elle permet de réduire l'in-

certitude au sein de régions bruitées tout en modélisant l'imprécision due à l'effet de volume partiel aux transitions entre les régions. En outre, nous avons comparé deux variantes de notre méthode : EVEII<sub>1</sub> et EVEII<sub>3</sub>. Les résultats ont rapporté qu'EVEII<sub>3</sub> est plus robuste face à l'inégale distribution de données observée entre les classes. Cependant, lorsque les données sont fortement bruitées, l'inégale répartition des données entre les classes s'estompe, conduisant à l'obtention de meilleures performances avec EVEII<sub>1</sub>, et à une chute des performances d'EVEII<sub>3</sub> qui ne parvient plus à détecter de données certaines et précises.

## 6.3 Évaluation d'EVEII sur des images de fantôme TEP

Dans cette section, nous évaluons notre méthode en la comparant à des méthodes déjà proposées dans la littérature pour la segmentation des images TEP au <sup>18</sup>FDG [Vauclin *et al.*, 2010; Zaidi *et al.*, 2002; Hatt *et al.*, 2008], et que nous avons déjà retenues dans le chapitre 2 (voir section 2.3), mais également pour la segmentation des images TEP au <sup>18</sup>FMiso [Rasey *et al.*, 1996; Choi *et al.*, 2010].

L'évaluation porte sur deux fantômes TEP physiques simulant les caractéristiques que l'on rencontre en routine clinique lors de l'acquisition d'images TEP au <sup>18</sup>FDG ou à la <sup>18</sup>FLT d'une part, et au <sup>18</sup>FMiso d'autre part. En effet, le premier fantôme présente une quantité de bruit semblable à celle rencontrée en routine clinique sur les images TEP au <sup>18</sup>FDG et à la <sup>18</sup>FLT. Le second fantôme présente une quantité de bruit bien plus importante, semblable à celle rencontrée sur les images TEP avec le traceur <sup>18</sup>FMiso.

La première section concerne le paramétrage de notre méthode. Les trois sections qui suivent portent sur l'évaluation sur trois fantômes différents.

### 6.3.1 Paramétrage de la méthode

#### 6.3.1.1 Apprentissage de la connaissance *a priori*

Pour réduire l'imprécision à la suite de l'étape d'EVEII, nous avons proposé section 5.2.3 d'utiliser une connaissance *a priori*. Cette connaissance est représentée à l'équation 5.15 sous la forme d'une fonction notée  $\beta(Cont, Vol)$ . À visée de réduction des imprécisions sur les images TEP, nous proposons dans cette section d'apprendre la valeur de cette fonction. La procédure d'apprentissage que nous présentons dans cette section s'inspire des méthodes de calibration des méthodes de seuillage permettant de trouver le seuil optimal pour segmenter la lésion [Vauclin *et al.*, 2010] (section 2.2.1.2.1).

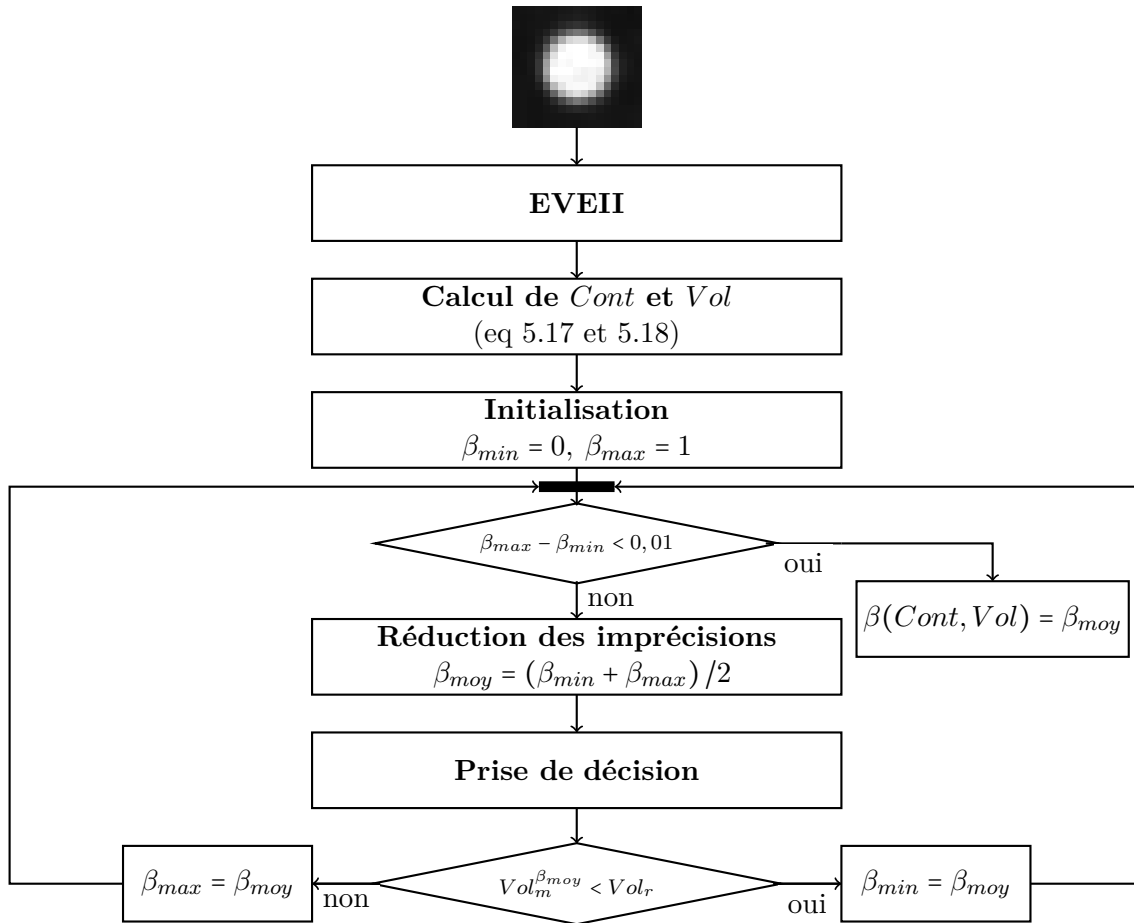


Figure 6.10 – Schéma donnant les différentes étapes du processus dichotomique mis en œuvre pour la mesure de la valeur de  $\beta$  lors de la phase d'apprentissage.




Figure 6.11 – Courbe présentant la fonction  $\beta(Cont, Vol) \in [0, 1]$  apprise sur un fantôme de Jaszczak pour différents volumes et contrastes.

### 6.3.1.1.1 Données d'apprentissage

Nous proposons d'utiliser le fantôme de Jaszczak présenté section 2.3.1.1 contenant 9 sphères afin d'apprendre la fonction  $\beta(Cont, Vol)$ .

Les 9 sphères font respectivement 0,39 ; 1,02 ; 2,04 ; 5,71 ; 11,59 ; 19,55 ; 28,04 ; 58,03 et 98,16 mL. Lors de l'acquisition, initialement ( $t = 0$ ), les sphères étaient toutes remplies avec une concentration d'activité égale à 60,7 kBq/mL, tandis que le fond était rempli avec une concentration de 2,6 kBq/mL. Ceci a permis de réaliser une première acquisition ( $t = 0$ ) avec un fort contraste entre les sphères et le fond ( $C_{S/F}$ ) égal à 22,9. Ensuite, de l'activité a successivement été ajoutée dans le fond du fantôme afin de réaliser respectivement des acquisitions avec des  $C_{S/F} = 18,1 ; 14,6 ; 11,1 ; 6,8 ; 5,2 ; 3,5$  et 1,7.

Les conditions d'acquisition et de reconstruction sont les mêmes que celles présentées section 2.3.1.1, à la différence du temps d'acquisition qui est à présent de 10 minutes. Cette durée permet d'obtenir des données présentant un faible bruit et ainsi de ne pas biaiser l'apprentissage.

Les deux plus petites sphères, dont le volume fait 0,39 et 1,02 mL, n'ont pas été utilisées pour la trop faible quantité de voxels les représentant. En effet, le volume  $Vol$  calculé à l'équation 5.18 tend vers 0. Pour la même raison, les sphères de 2,04 et 5,71 mL pour le contraste  $C_{S/F} = 1,7$  n'ont pas été utilisées. Au total, 54 objets d'apprentissage correspondant à 54 jeux différents de sphère-contraste ont été utilisés comme données d'apprentissage.

### 6.3.1.1.2 Méthode d'apprentissage

À partir de chacune des sphères, notre méthode d'estimation des masses de croyance (EVEII) est appliquée, suivie de la mesure du contraste  $Cont$  et du volume  $Vol$  (équations 5.17 et 5.18), puis notre méthode de réduction d'imprécision est appliquée en faisant varier une valeur notée  $\beta_{moy}$  dans l'intervalle  $[0, 1]$ . Pour chaque valeur de  $\beta_{moy}$ , une région segmentée est obtenue à l'issue de la prise de décision. Soit  $Vol_m^{\beta_{moy}}$  son volume. Pour chacune des sphères, nous proposons de retenir la valeur de  $\beta_{moy}$  minimisant l'écart entre le volume mesuré  $Vol_m^{\beta}$  et le volume réel de la sphère  $Vol_r$ . Notons que la recherche de la valeur de  $\beta \in [0, 1]$  pour chaque sphère a été réalisée par l'intermédiaire d'une dichotomie afin de limiter le nombre d'itérations. Le processus dichotomique permettant de mesurer la valeur de  $\beta(Cont, Vol)$  pour une sphère d'un volume donné et à un contraste donné est illustré Figure 6.10.

En apprenant une valeur de  $\beta_{moy}$  pour les sphères de l'ensemble d'apprentissage, un ensemble de 54 valeurs de  $\beta(Cont, Vol)$  est obtenu. Par interpolation linéaire, nous obtenons la courbe présentées Figure 6.11. Comme nous pouvons le constater, plus faibles sont le volume  $Vol$  et le contraste  $Cont$ , plus grande est la valeur de  $\beta(Cont, Vol)$ .






Figure 6.12 – Exemple d’images TEP acquises à partir du fantôme de Jaszczak à 9 sphères (Fantôme 1).

### 6.3.2 Fantôme 1

#### 6.3.2.1 Matériels et méthodes

##### 6.3.2.1.1 Fantôme de Jaszczak

Le premier fantôme que nous proposons d’utiliser est le fantôme cylindrique de Jaszczak que nous avons déjà décrit section 2.3.1.1. Pour rappel, il compte neuf sphères de volume compris entre 0,43 mL et 97,3 mL (0,43 ; 0,99 ; 2,08 ; 3,78 ; 11,6 ; 19,3 ; 27,9 ; 58,1 et 97,3 mL), et cinq contrastes entre les sphères et le fond sont considérés :  $C_{S/F} = 7,7$  ; 6,3 ; 4,9 ; 3,4 et 2,0. Les images acquises, par pas d’acquisition de durée 3 min, sont présentées Figure 6.12 pour les différents contrastes.

En outre, rappelons que la plus petite des sphères, dont le volume fait 0,43 mL, n’était pas visible sur les deux plus faibles contrastes ( $C_{S/F} = \{2,0 ; 3,4\}$ ). La sphère de 0,99 mL n’était également pas visible avec le contraste 2. Au total, 43 sphères étaient visibles et ont permis d’évaluer les méthodes.

##### 6.3.2.1.2 Méthodes évaluées

En fin de chapitre 2, nous avons comparé les résultats d’estimation du volume des sphères à partir de sept méthodes de segmentation et retenu trois d’entre elles : le seuillage adaptatif (Sad) [Vauclin *et al.*, 2010] car il présente un bon comportement pour les sphères de gros volume, l’algorithme FCM introduit dans [Bezdek, 1981] qui semble robuste vis-à-vis du contraste, et FLAB qui possède un bon comportement, en particulier pour les sphères de petit volume.

Nous proposons dans cette section de comparer deux variantes de notre méthode (EVEII<sub>1</sub> et EVEII<sub>3</sub>) à ces trois méthodes. La méthode EVEII<sub>1</sub> est tout d’abord évaluée sans notre méthode de réduction des imprécisions, puis avec notre méthode de réduction des imprécisions par l’apprentissage de la fonction  $\beta$  (voir section 5.2.3). Ces deux méthodes sont respectivement notées EVEII<sub>1</sub> et EVEII<sub>1 $\beta$</sub> . Enfin, la méthode EVEII<sub>3</sub> est également évaluée avec la méthode de

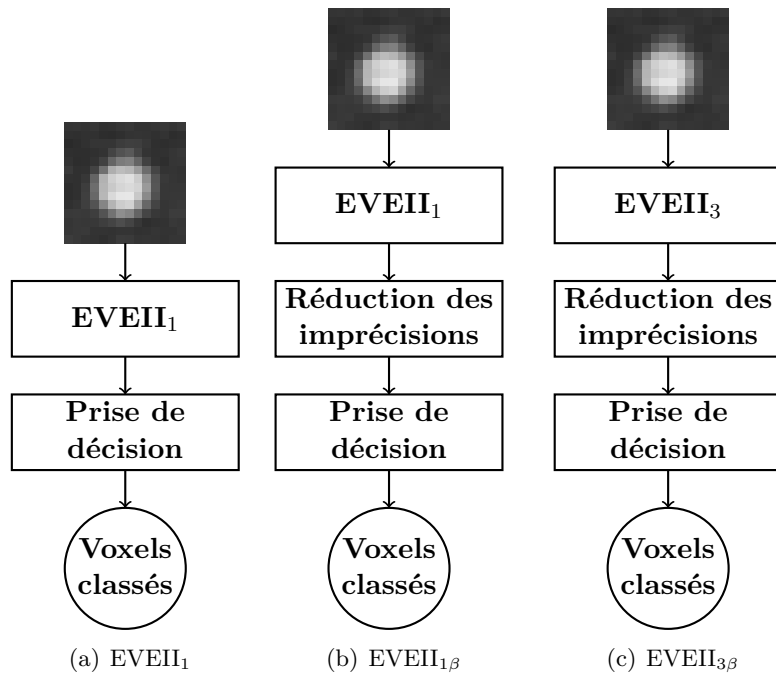


Figure 6.13 – Schémas illustrant les différentes étapes des trois variantes de notre méthodes pour la segmentation du fantôme de Jaszczak. (a), (b) et (c) illustrent les différentes étapes pour les variantes notées EVEII<sub>1</sub>, EVEII<sub>1β</sub> et EVEII<sub>3β</sub> respectivement.

réduction des imprécisions. À cet effet, elle est notée EVEII<sub>3β</sub>. Les différentes étapes de notre méthode sont présentées Figure 6.13. L'élément structurant, permettant de régler l'influence du voisinage, est un filtre Gaussien de FWHM égale à 6 mm.

### 6.3.2.1.3 Analyse des données

Dans le cadre de notre étude comparative, les indices volumiques ont été utilisés afin d'évaluer les méthodes. Les volumes lésionnels des données fantôme sont connus et servent de référence.

Dans un premier temps, l'erreur relative absolue ( $|E_r|$ ), donnée en pourcentage (%), entre le volume mesuré et le volume de référence, a été calculée selon l'équation :

$$E_r = 100 \cdot \frac{|Vol_m - Vol_r|}{Vol_m}. \quad (6.2)$$

La moyenne des erreurs relatives mesurées, à contrastes et/ou à sphères confondues, permettent d'observer le comportement des méthodes en fonction du contraste ou de la taille des sphères.

Dans un second temps, une représentation de Bland et Altman a été réalisée [Bland et Altman, 1999]. Elle permet de représenter, sous forme de graphique, la différence entre le volume mesuré  $Vol_m$  et le volume de référence  $Vol_r$  en fonction du volume de référence [Krouwer, 2008].

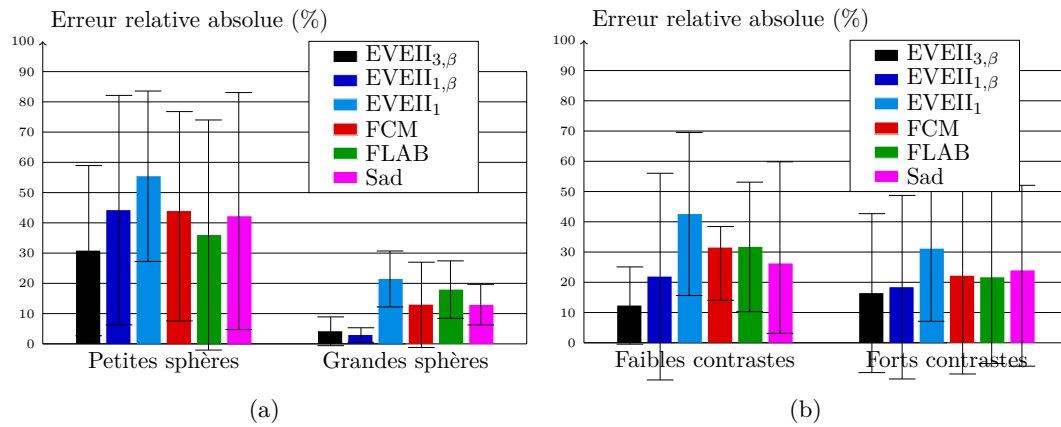


Figure 6.14 – Pourcentages d’erreurs relatives absolues moyennes, accompagnés de leur écart type, du volume mesuré, pour les petites ( $\leq 3,78$  mL) et les grandes sphères ( $\geq 11,6$  mL) (Figure (a)), et pour les faibles ( $\leq 3,5$ ) et les forts ( $\geq 5$ ) contrastes (Figure (b)), avec les méthodes de segmentation Sad, FLAB, FCM, EVEII<sub>1</sub> et EVEII<sub>3</sub>.

Appliqué pour chacune des méthodes, elle permet de conclure ou pas à la corrélation de chaque méthodes par rapport à la référence. Sur un tel graphique, le biais entre la méthode et la référence, ainsi que l’indice de concordance sont également représentés. Le biais est obtenu par le calcul de la moyenne des différences. Il donne une indication sur la tendance d’une méthode à produire des valeurs systématiquement plus basses ou plus élevées que la référence. L’indice de concordance est obtenu par le calcul de l’écart type des différences. Il correspond à l’écart (entre  $\pm 1,96$  fois l’écart-type des différences à la valeur moyenne) où sont comprises 95% des différences. Il donne une indication sur la tendance d’une méthode à donner une mesure proche du biais. En outre, nos analyses de Bland et Altman sont accompagnées de la mesure d’une *p-value*. Elle correspond à la probabilité de rejeter à tort l’hypothèse nulle. Dans notre application, l’hypothèse nulle correspond à l’hypothèse qu’il n’y a pas de différence entre les volumes mesurés par une méthode et les volumes de référence. À partir d’une valeur seuil de la *p-value*, il est possible de rejeter l’hypothèse nulle. La valeur seuil utilisée est 5 %. En deçà de 5 %, l’hypothèse nulle est rejetée. Au delà, il n’y a pas de présomption contre l’hypothèse nulle.

### 6.3.2.2 Résultats

Les erreurs relatives absolues moyennes, obtenues pour chacune des méthodes, sont données Figure 6.14. Les résultats sont présentés sous forme d’histogramme, en distinguant les petites des grandes sphères, mais pas les contrastes (Figure 6.14(a)), puis en distinguant les faibles des forts contrastes, mais pas la taille des sphères (Figure 6.14(b)). Les deux histogrammes présentent également l’écart-type des erreurs relatives absolues mesurées.

Comme nous pouvons le constater Figure 6.14(a), pour les grandes sphères, des pourcentages d'erreur relative inférieurs à 10 % sont obtenus avec les méthodes  $EVEII_{1\beta}$  et  $EVEII_{3\beta}$ , alors que les autres méthodes donnent des pourcentages supérieurs à 10 %. Pour les petites sphères, l'ensemble des méthodes donne des pourcentages d'erreur très élevés en moyenne, accompagnés d'un fort écart-type. Ces faibles performances, et les écart-types élevés, sont dûs à la forte erreur relative (avoisinant 100 %) obtenu avec chaque méthode pour la plus petite des sphères (0,43 mL). Cependant nous pouvons voir que le pourcentage d'erreur le plus faible est obtenu avec  $EVEII_{3\beta}$ . En outre, nous pouvons remarquer qu' $EVEII_1$  est moins performante que l'algorithme FCM. Néanmoins, en intégrant ensuite notre méthode de réduction des imprécisions (méthode  $EVEII_{1\beta}$ ), les performances sont améliorées. Cette amélioration est encore plus marquée avec  $EVEII_{3\beta}$ . À la Figure 6.14(b), les erreurs moyennes sont données en fonction du contraste. Comme nous pouvons le remarquer, il n'y a pas de grande variation du pourcentage d'erreur entre les faibles et les forts contrastes pour l'ensemble des méthodes. Les meilleurs résultats sont encore une fois obtenus avec  $EVEII_{3\beta}$ .

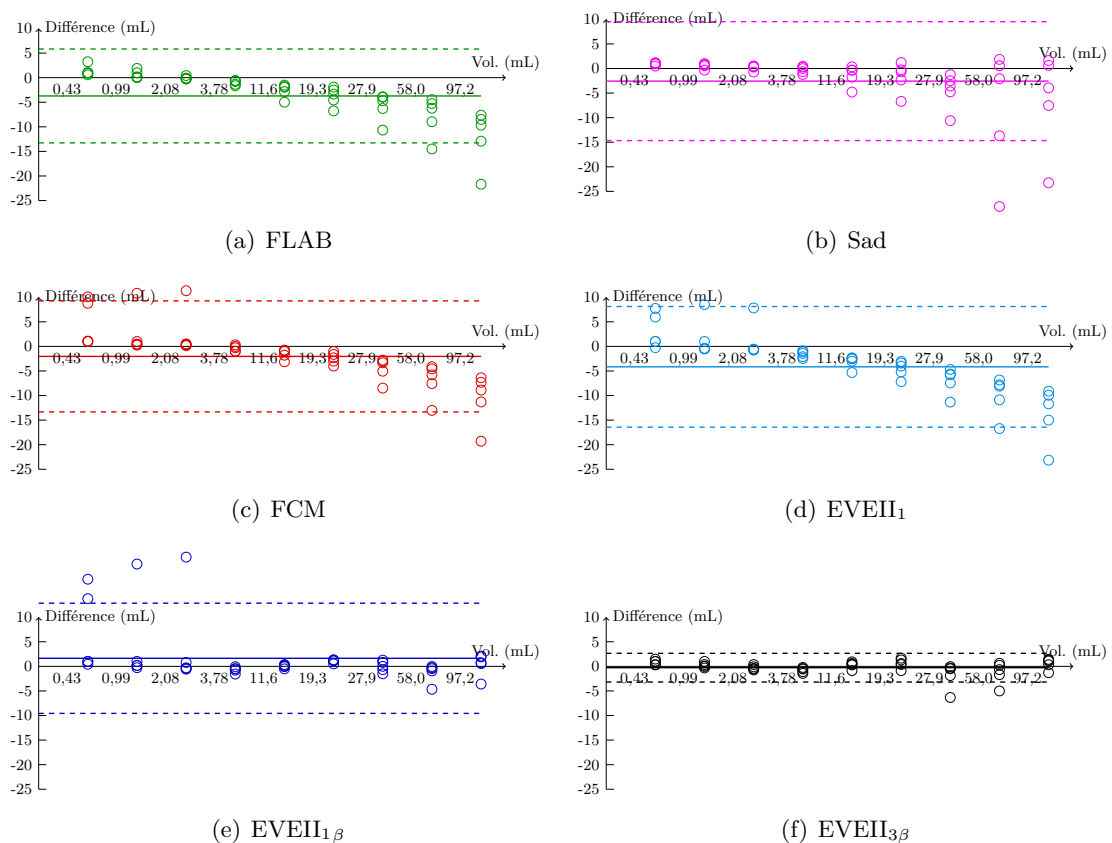


Figure 6.15 – Figures de Bland et Altman présentant les différences entre les volumes mesurés et les volumes de référence en fonction des volumes de référence pour six méthodes évaluées sur le fantôme de Jaszczak. Les traits pleins et pointillés correspondent respectivement aux biais et aux indices de concordance.

Méthode	Biais	Indice de concordance à 95 %	<i>p value</i>
FLAB	-3,72	[-13,44 ; 6,01]	$< 10^{-4}$
Sad	-2,71	[-14,66 ; 9,52]	0,603
FCM	-2,04	[-13,32 ; 9,24]	$< 10^{-4}$
EVEII <sub>1</sub>	-4,16	[-16,42 ; 8,10]	$< 10^{-4}$
EVEII <sub>1β</sub>	1,64	[-9,57 ; 12,85]	0,081
EVEII <sub>3β</sub>	-0,27	[-3,19 ; 2,65]	0,162

Tableau 6.1 – Statistiques descriptives des représentations de Bland et Altman pour les six méthodes comparées sur le fantôme de Jaszczak. Les *p value* ont été obtenues par un test de Student apparié.

Une figure de Bland et Altman est donnée Figure 6.15 pour chacune des six méthodes. Cette figure s'accompagne du Tableau 6.1 présentant les valeurs du biais, de l'indice de concordance et la valeur de *p*. Comme nous pouvons le remarquer Figure 6.15(f), EVEII<sub>3β</sub> est la méthode qui estime le mieux les volumes avec un très faible biais (-0,27 mL) et un indice de concordance étroit ([-3,19 mL ; 2,65 mL]). FLAB, Sad, FCM et EVEII<sub>1</sub> ont toutes tendance à sous-estimer le volume des sphères avec un biais variant de -2 à -4 mL. Qui plus est, ces biais sont accompagnés d'un indice de concordance présentant un large écart, signifiant que les volumes sont estimés avec une faible précision. Pour ces quatre méthodes, les biais importants et les larges écarts d'indice de concordance résultent principalement de la sous estimation du volume des grandes sphères. Avec FCM (Figure 6.15(c)), nous pouvons en outre observer que quatre volumes mesurés, pour les sphères de 0,43, 0,99 et 2,08 mL, présentent une sur-estimation du volume très importante (de l'ordre de 10 mL). Elle est due à l'incapacité de l'algorithme à détecter les petites sphères à faible contraste. Sans surprise, ces quatre sur-estimation des volumes sont également observées avec les méthodes EVEII<sub>1</sub> et EVEII<sub>1β</sub>, où l'estimation des masses de croyance est réalisée, à l'initialisation, par l'intermédiaire de l'algorithme FCM. Comme nous pouvons l'observer en comparant les Figures 6.15(c) et (d), EVEII<sub>1</sub> sous-estime davantage les volumes des sphères par rapport à l'algorithme FCM. Cette sous-estimation est corrigée avec EVEII<sub>1β</sub>, intégrant le processus de réduction des imprécisions suite à l'estimation des croyances (Figure 6.15(e)). Néanmoins, comme observé Tableau 6.1, un indice de concordance présentant un large écart est observé avec EVEII<sub>1β</sub>. Ce large écart est causé par la forte sur-estimation des petites sphères à faible contraste. Ce phénomène n'est pas observé avec EVEII<sub>3β</sub>. Enfin, nous pouvons observer Tableau 6.1 que trois méthodes (Sad, EVEII<sub>1β</sub> et EVEII<sub>3β</sub>) donnent des *p-value* supérieures au seuil de 5 %, montrant que ces méthodes donnent des mesures non statistiquement différentes des volumes réels des sphères.

### 6.3.2.3 Discussion

L'évaluation d'EVEII a porté sur un fantôme de Jaszczak contenant neuf sphères et cinq contrastes en comparaison à trois méthodes de la littératures proposées pour la segmentation des images TEP au  $^{18}\text{FDG}$ . Les sphères du fantôme sont homogènes, et ne permettent pas de se rapprocher de toutes les données rencontrées en routine clinique. Cependant, la comparaison des méthodes sur les sphères de ce fantôme, dont les volumes sont connus, permet d'observer le comportement des méthodes face à la faible résolution spatiale des images et la petitesse de certaines sphères. Dans un premier temps, l'évaluation a porté sur l'analyse de l'erreur d'estimation des volumes vis-à-vis de la taille des sphères et du contraste. Dans un second temps, elle a porté sur l'analyse, par l'intermédiaire de figures de Bland et Altman, de la tendance des méthodes à offrir une estimation du volume juste et fidèle.

Les résultats, Figure 6.14, de mesure des erreurs relatives absolues moyennes ont permis de comparer chaque méthode en fonction de la taille des sphères et du contraste. EVEII<sub>3 $\beta$</sub>  donne le plus faible pourcentage d'erreur. Cela témoigne d'une part de l'importance de l'étape de réduction des imprécisions, et d'autre part de l'importance d'intégrer l'étape de fusion des informations de voisinage dans l'algorithme FCM.

La figure de Bland et Altman, Figure 6.15(f), permet d'observer la tendance des méthodes à sur- ou sous-estimer le volume des sphères. Comme nous pouvons de nouveau le voir, la méthode EVEII<sub>3 $\beta$</sub>  est incontestablement la méthode présentant la meilleure estimation du volume, avec un biais proche de 0 mL, un indice de concordance présentant un faible écart et une valeur de  $p = 0,162$ . Les méthodes FLAB, Sad, FCM et EVEII<sub>1</sub> sous-estiment largement le volume des sphères, en commettant une erreur proportionnelle au volume des sphères. EVEII<sub>1 $\beta$</sub>  et EVEII<sub>3 $\beta$</sub>  sont les seules méthodes à ne pas commettre d'erreur proportionnelle. Avec les méthodes FCM, EVEII<sub>1</sub> et EVEII<sub>1 $\beta$</sub> , nous avons en outre pu remarquer qu'une très forte sur-estimation du volume était présente pour quatre des petites sphères. Ceci est dû à l'incapacité de l'algorithme FCM à estimer les sphères de petit volume, pour la même raison que celle évoquée sur la seconde image simulée section 6.2.1.1. L'algorithme FCM n'est pas robuste à l'inégale répartition des données entre les classes. Cette erreur d'estimation est cependant corrigée avec EVEII<sub>3 $\beta$</sub>  intégrant l'étape de combinaison disjonctive des informations de voisinage au sein de l'algorithme FCM (voir Figure 6.15(f)). Les  $p$  values sont supérieures au seuil pour les méthodes Sad, EVEII<sub>1 $\beta$</sub>  et EVEII<sub>3 $\beta$</sub> . Il est intéressant de noter que ces trois méthodes possèdent une étape de calibration ou d'apprentissage d'une connaissance *a priori* sur des données fantôme, leur permettant de s'adapter à la segmentation des données TEP présentant une très faible

résolution spatiale. Bien que cette étape puisse être vue comme une limite, il semble difficile d'exclure ce type d'apprentissage pour arriver à une segmentation optimale des images.

### 6.3.3 Fantôme 2

#### 6.3.3.1 Matériels et méthodes

##### 6.3.3.1.1 Fantôme NEMA IEC



Figure 6.16 – Fantôme NEMA IEC (Data Spectrum Corporation, Hillsborough, NC, USA) contenant six sphères.




Figure 6.17 – Images TDM et TEP acquises à partir du fantôme NEMA IEC à 6 sphères. Une coupe TEP pour chacun des contrastes est présentée.

Les données ont été acquises sur un fantôme NEMA IEC (Data Spectrum Corporation, Hillsborough, NC, USA). Il s'agit d'un fantôme cylindrique (voir Figure 6.16), dont le diamètre et la hauteur interne font environ 20 cm. Il contient six sphères (Figure 6.17) de volume respectif 0,54 ; 1,15 ; 2,63 ; 5,53 ; 11,6 et 26,2 mL.

<b>Patient</b>	#1	#2	#3
<b>Données cliniques</b>			
Sexe ({M,F})	M	M	M
Age (ans)	67	48	58
Pathologie	Indifférenciée (T4N2)	Adénocarcinome (TxN3)	Carcinome épidermoïde non petites cellules (T2N2)
<b>Acquisition</b>			
Activité administrée (MBq)	291	178	160
Délai après injection (min)	202	211	180
Durée d'acquisition (min)	6	6	7
<b>Images</b>			
Fond :			
<i>Moyenne (Bq/mL)</i>	998	392	350
<i>Écart-type (Bq/mL)</i>	236	94	115
<i>Moyenne/Écart-type</i>	4,22	4,17	3,04
Hyper-fixation :			
<i>Volume (mL)</i>	15,8	3,6	2,8
<i>Moyenne (Bq/mL)</i>	2144	919	840
<i>Contraste mesuré</i>	2,15	2,14	2,63

Tableau 6.2 – Caractéristiques des images TEP au  $^{18}\text{FMiso}$  (protocole RTEP4).

Pour déterminer les conditions expérimentales de nos acquisitions du fantôme 2, nous nous sommes basés sur les données de trois patients inclus dans l'essai clinique RTEP4<sup>1</sup> [Vera *et al.*, 2011] dont le Professeur P. Vera était le coordinateur et le centre Henri-Becquerel était promoteur. Dans le Tableau 6.2 sont regroupées les données cliniques concernant les patients, ainsi que les caractéristiques des acquisitions TEP au  $^{18}\text{FMiso}$ , ainsi que des images.

<b>Fantôme</b>	Contraste 2,7	Contraste 3,3	Contraste 3,8
<b>Acquisition</b>			
Concentration d'activité (Bq/mL)	445	370	319
<b>Images</b>			
Fond :			
<i>Moyenne (Bq/mL)</i>	378	375	403
<i>Écart-type (Bq/mL)</i>	113	138	116
<i>Moyenne/Écart-type</i>	3,34	2,71	3,47
Grande sphère (26,2 mL)			
<i>Moyenne (Bq/mL)</i>	839	1178	1479
<i>Contraste mesuré</i>	2,21	3,14	3,66
Petite sphère (2,63mL)			
<i>Moyenne (Bq/mL)</i>	NM	912	1009
<i>Contraste mesuré</i>	NM	2,43	2,5

Tableau 6.3 – Caractéristiques des images TEP issues du fantômes NEMA-IEC. NM : Non Mesurable.

1. Protocole RTEP4 (Numéro EudraCT<sup>o</sup> : 2008-001821-33) : Étude de la modification de la fixation de Fluoro-2-deoxy-D-glucose (FDG), du fluoro-misonidazole (F-Miso) et de la 3'deoxy-3-fluoro-thymidine (FLT) mesurée en Tomographie par Émission de Positons (TEP) chez des patients avant et en cours de radiothérapie exclusive ou de radiochimiothérapie concomitante pour le cancer bronchique primitif.



Lors de l'acquisition, initialement ( $t = 0$ ), les sphères étaient toutes remplies avec une concentration d'activité égale à 1,2 kBq/mL, tandis que le fond était rempli avec une concentration de 0,31 kBq/mL. Ceci a permis de réaliser une première acquisition ( $t = 0$ ) avec un rapport de contraste entre les sphères et le fond ( $C_{S/F}$ ) égal à 3,8. Ensuite, de l'activité a successivement été ajoutée dans le fond du fantôme à  $t = 30, 60$  min afin de réaliser respectivement des acquisitions avec des  $C_{S/F} = 3,3$  et 2,7. Les données ont été acquises en *List-mode* pendant 21 minutes, nous permettant de reconstruire les données avec des temps d'acquisition variant entre 0 et 21 minutes pour chacun des contrastes. Afin d'obtenir des statistiques de comptage proches de celles rencontrées en clinique, la durée a été fixée à 7 minutes. Dans ces conditions, les caractéristiques des images TEP sont données Tableau 6.3.

De plus, neuf échantillons bootstraps ont été extraits, par pas de 93 secondes parmi les 21 minutes. Cela a permis d'obtenir pour chaque temps, neuf répliques, et ainsi de permettre de mieux évaluer, statistiquement, le comportement des méthodes face au bruit important dans les images dû à la faible concentration du radiotracer. À titre comparatif, la concentration d'activité dans les sphères du fantôme de Jaszczak, utilisé dans la précédente section pour simuler des acquisitions cliniques au  $^{18}\text{F}$ FDG, était 35 fois plus importante à  $t = 0$  (41,6 kBq/mL). L'objectif est ici de se rapprocher des faibles concentrations observées en imagerie TEP avec le traceur  $^{18}\text{F}$ Miso.

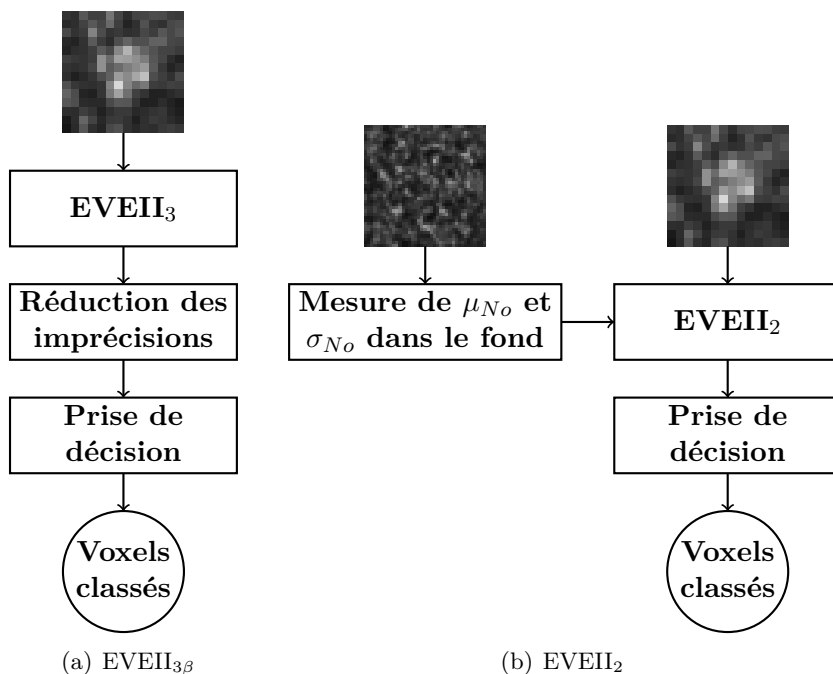


Figure 6.18 – Schémas illustrant les différentes étapes des deux variantes de notre méthode pour la segmentation du fantôme NEMA-IEC. (a) et (b) illustrent les différentes étapes pour les variantes notées  $\text{EVEII}_{3\beta}$  et  $\text{EVEII}_2$  respectivement.

Les plus petites sphères (0,54 et 1,15 mL) n'ont pas été considérées car elles sont difficiles à distinguer. Seules les trois plus grandes sphères (5,53 ; 11,6 et 26,2 mL), et la sphère de 2,63 mL avec les contrastes supérieurs à 3, ont été utilisées. Au total, avec les différentes tailles des sphères, les divers contrastes et les multiples répliques, 99 sphères ont été considérées.

### 6.3.3.1.2 Méthodes évaluées

Nous avons évalué l'ensemble des méthodes déjà étudié avec le fantôme de Jaszczak, dans la précédente section, à l'exception de nos méthodes  $EVEII_1$  et  $EVEII_{1\beta}$  donnant de moins bons résultats qu' $EVEII_{3\beta}$ . En outre, nous avons évalué deux méthodes notées  $HNR_{1,3}$  et  $S_{SUV_{1,4}}$ , respectivement proposées dans [Choi *et al.*, 2010] et [Rasey *et al.*, 1996] pour la segmentation des images TEP acquises avec le traceur  $^{18}\text{FMiso}$ .  $HNR_{1,3}$ , pour *Hypoxic-to-Normoxic Ratio*, est une méthode de seuillage dont le seuil vaut 1,3 fois la moyenne des intensités mesurées dans le fond.  $S_{SUV_{1,4}}$  est également une méthode de seuillage, mais avec comme valeur seuil une SUV de 1,4. Cette dernière méthode nécessite de convertir les intensités des voxels des fantômes en SUV (voir section 1.1.5.2.2). Enfin, nous avons évalué  $EVEII_2$ , proposé section 5.2.1.4.2 pour la segmentation des lésions tumorales en milieu présentant un faible rapport signal sur bruit. Les différentes étapes d' $EVEII_{3\beta}$  et  $EVEII_2$  sont schématisées Figure 6.18. Notons que pour  $EVEII_2$  et  $HNR_{1,3}$ , la région permettant de mesurer la moyenne des intensités dans le fond est la même et a été sélectionnée manuellement pour chaque fantôme.

### 6.3.3.1.3 Analyse des données

Dans le cadre de notre étude comparative, nous proposons de reprendre la même analyse de Bland et Altman que celle précédemment utilisée, basée sur les différences d'estimation des volumes avec chaque méthode. Neuf répliques étant disponibles pour chaque contraste, les différences d'estimation des volumes avec chaque méthode dans l'analyse de Bland et Altman correspondent à des moyennes sur les neuf répliques. L'analyse des erreurs relatives n'a pas été utilisée pour ce fantôme en raison de l'environnement très bruité conduisant à des pourcentages très importants pour l'ensemble des méthodes. En revanche, le résultat de la segmentation d'une des sphères est présenté en vue d'apprécier, visuellement, le comportement des méthodes. De plus, une analyse du volume estimé, moyenné pour l'ensemble des répliques, en fonction du volume de chaque sphère et pour chaque méthode est présentée sous forme d'histogramme. Les écart-types d'estimation des volumes pour l'ensemble des répliques sont également présentés. L'objectif est d'observer la variabilité d'estimation des volumes en fonction des répliques.

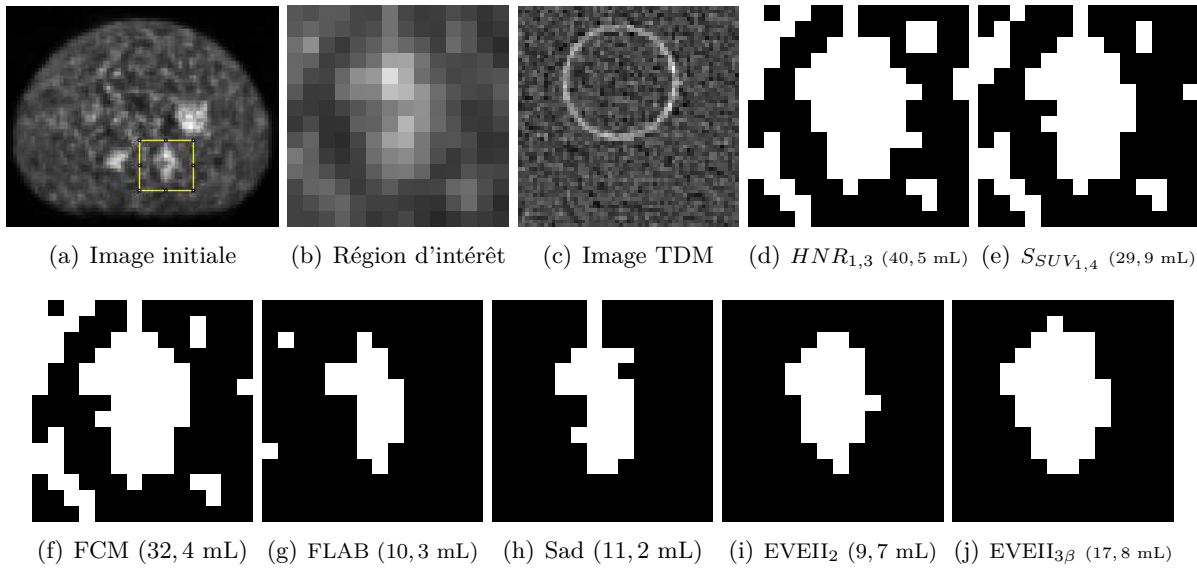


Figure 6.19 – Résultats de la segmentation de la sphère de 11,6 mL du fantôme NEMA IEC (7 minutes,  $C_{S/F} = 2,7$ ) pour les sept méthodes de segmentation évaluées.

### 6.3.3.2 Résultats

La Figure 6.19 donne un exemple de résultat de segmentation d'une sphère de 11,6 mL (7 minutes,  $C_{S/F} = 2,7$ ) pour l'ensemble des méthodes évaluées. Cette figure donne également, en légende, le volume obtenu avec chaque méthode. Comme nous pouvons le remarquer, les méthodes  $HNR_{1,3}$ ,  $SSUV_{1,4}$ , et FCM ne permettent pas de segmenter la sphère, et sur-estiment largement son volume. Les volumes estimés avec les méthodes FLAB et Sad sont très proches de la réalité, mais sont éloignés de la forme de la sphère. Enfin, les méthodes EVEII<sub>2</sub> et EVEII<sub>3β</sub> donnent un résultat plus proche de la réalité. La différence entre ces deux méthodes est que le volume obtenu avec EVEII<sub>2</sub> est plus proche du volume réel de 11,6 mL (9,7 mL pour EVEII<sub>2</sub> contre 17,8 mL pour EVEII<sub>3β</sub>).

Les graphiques de Bland et Altman sont donnés Figure 6.20 pour chacune des cinq méthodes (FCM, FLAB, Sad, EVEII<sub>2</sub> et EVEII<sub>3β</sub>). Les méthodes de seuillage  $HNR_{1,3}$  et  $SSUV_{1,4}$  n'ont pas été considérées ici du fait qu'elles sur-estiment très largement les volumes, et donnent des résultats inexploitable. Les graphiques donnent les différences d'estimation des volumes en fonction des volumes réels. En outre, de manière à observer l'influence du changement de contraste, les différences d'estimation sont représentés par trois symboles en fonction du contraste : un carré (□) pour le plus faible contraste ( $C_{S/F} = 2,7$ ), un losange (◇) pour le contraste intermédiaire ( $C_{S/F} = 3,3$ ), et un cercle (○) pour le contraste le plus élevé ( $C_{S/F} = 3,8$ ). Comme nous pouvons le voir, FLAB et Sad ont tendance à systématiquement sous-estimer les gros volumes ( $> 11$  mL). La méthode EVEII<sub>3β</sub> a tendance à sur-estimer le volume

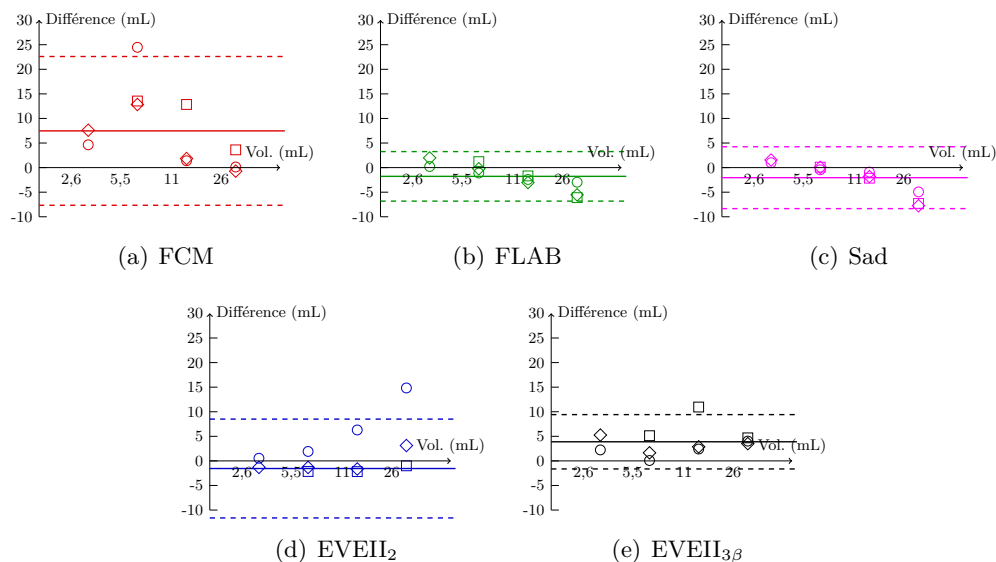


Figure 6.20 – Figures de Bland et Altman présentant les différences entre les volumes moyens mesurés et les volumes de référence en fonction des volumes de référence pour six méthodes évaluées sur le fantôme IEC NEMA. Les traits pleins et pointillés correspondent respectivement aux biais et aux indices de concordance.

de toutes les sphères. Avec l’algorithme FCM, la sur-estimation est davantage marquée. Enfin, EVEII<sub>2</sub> donne des différences qui sont d’autant plus importantes que le volume des sphères est important. La figure s’accompagne du Tableau 6.4 présentant les valeurs du biais, de l’indice de concordance et  $p$ . Un biais proche de zéro est obtenu avec les méthodes FLAB, Sad et EVEII<sub>2</sub> (−1,78, −2,05 et −1,55 mL). Seulement, l’indice de concordance est plus large avec EVEII<sub>2</sub>. Avec EVEII<sub>3β</sub>, l’indice de concordance obtenu est du même ordre de grandeur qu’avec FLAB et Sad, mais le biais est plus important (3,89 mL). Avec FCM, le biais particulièrement important (7,74 mL) témoigne de son incapacité à segmenter les images largement bruitées. Enfin, des valeurs de  $p$ , très faibles, sont obtenus pour FLAB, Sad, FCM et EVEII<sub>3β</sub>. Seule la méthode EVEII<sub>2</sub> dont une valeur de  $p$  importante (0,33).

Méthode	Biais	Indice de concordance à 95 %	$p$ value
FLAB	−1,78	[−6,81 ; 3,25]	0,043
Sad	−2,05	[−8,34 ; 4,24]	0,059
FCM	7,74	[−7,66 ; 22,6]	0,0093
EVEII <sub>2</sub>	−1,55	[−11,6 ; 8,50]	0,3387
EVEII <sub>3β</sub>	3,89	[−1,63 ; 9,41]	0,001

Tableau 6.4 – Statistiques descriptives des représentations de Bland et Altman pour les six méthodes comparées sur le fantôme NEMA-IEC.

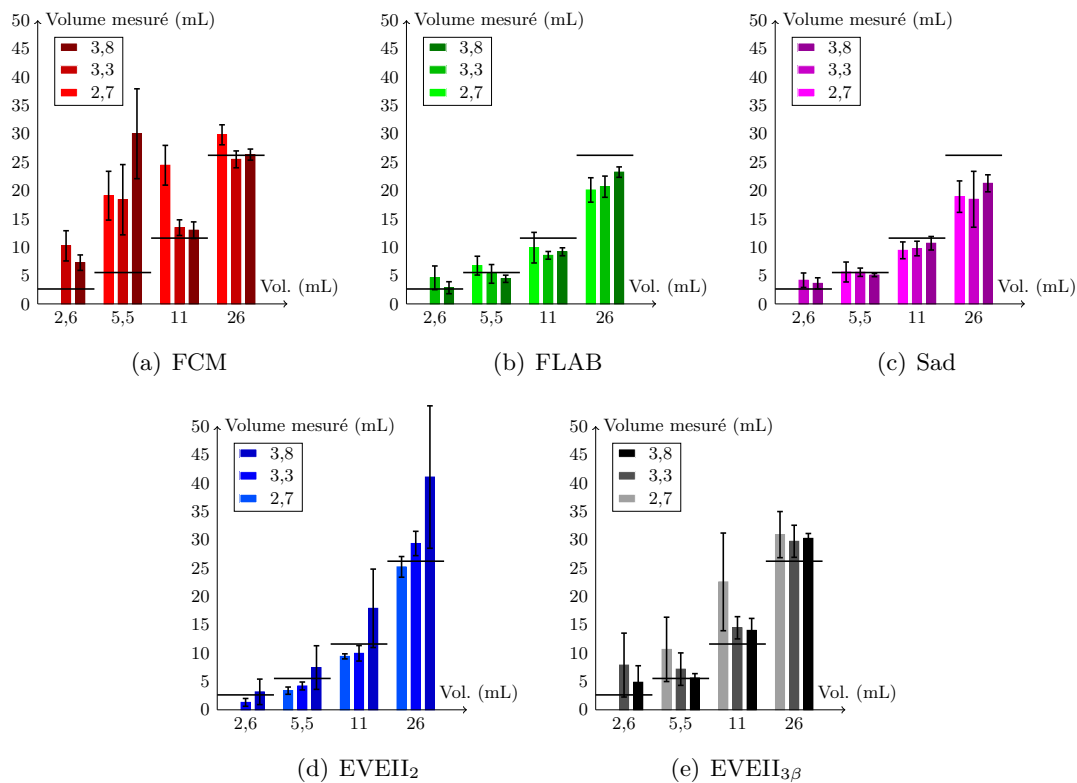


Figure 6.21 – Histogramme des volumes mesurés moyens accompagnés de leur écart-type calculés pour l’ensemble des répliques, avec les méthodes de segmentation FCM, FLAB, Sad, EVEII<sub>2</sub> et EVEII<sub>3β</sub>. Les barres horizontales correspondent aux volumes réels des sphères.

Les volumes mesurés moyens accompagnés de leur écart-type sont présentés à la Figure 6.21. Les résultats sont présentés pour chaque méthode sous forme d’histogramme en fonction de la taille des sphères et en distinguant les trois contrastes (de gauche à droite : du plus faible au plus fort contraste). Comme nous pouvons le remarquer, les volumes sont mieux estimés avec les méthodes FLAB, Sad et EVEII<sub>3β</sub>. Pour FLAB et Sad, ils sont accompagnés d’un faible écart-type, témoignant de la robustesse des deux méthodes vis-à-vis du bruit qui varie sur l’ensemble des répliques. Avec EVEII<sub>3β</sub>, un écart-type assez important est observé pour les sphères à faible contraste, mais pas pour les forts contrastes (voir Figure 6.21(e)). *A contrario*, la méthode EVEII<sub>2</sub>, Figure 6.21(d), donne les moins bons résultats pour le contraste le plus élevé.

### 6.3.3.3 Discussion

L’évaluation d’EVEII a porté sur un fantôme NEMA-IEC contenant quatre sphères et trois faibles contrastes. Les très faibles activités enregistrées dans les sphères et dans le fond du fantôme permettent de se rapprocher des images TEP au <sup>18</sup>F Miso (voir Tableaux 6.2 et 6.3), et ainsi d’évaluer les méthodes sur des images présentant un très faible rapport signal sur

bruit ([2,7 - 3,5], voir Tableau 6.3). Les méthodes évaluées sont l'algorithme FCM, FLAB, Sad, EVEII<sub>2</sub>, EVEII<sub>3 $\beta$</sub> ,  $S_{SUV_{1,4}}$  et  $HNR_{1,3}$ . Dans un premier temps, l'évaluation a porté sur la présentation du résultat de segmentation d'une des sphères avec chacune des sept méthodes. Dans un deuxième temps l'évaluation a porté sur l'analyse, par l'intermédiaire de figures de Bland et Altman, de la tendance des méthodes à offrir une estimation du volume juste et fidèle malgré le bruit. Dans un troisième temps, l'histogramme des volumes mesurés moyens accompagnés de leur écart-type calculés pour l'ensemble des répliques ont été présentés pour chaque méthode.

La Figure 6.19, présentant le résultat de la segmentation d'une des sphères, a permis d'écartier les deux méthodes de seuillage,  $HNR_{1,3}$  et  $S_{SUV_{1,4}}$ , donnant des résultats de segmentation très éloignés de la vérité. En outre, elle a permis de montrer que les méthodes EVEII<sub>2</sub> et EVEII<sub>3 $\beta$</sub>  sont moins sensibles au bruit que les méthodes FCM, FLAB et Sad donnant des résultats de segmentation dont la forme est très éloignée de celle d'une sphère. En comparant EVEII<sub>2</sub> et EVEII<sub>3 $\beta$</sub> , nous avons remarqué qu'EVEII<sub>2</sub> offre une meilleure estimation du volume. La sur-estimation du volume avec EVEII<sub>3 $\beta$</sub>  s'explique par la présence très importante de bruit. En effet, le bruit a un impact sur la quantité de données représentées sur l'hypothèse  $\{\omega_1, \omega_2\}$  après l'étape EVEII<sub>3</sub>, et conduit à un transfert trop important de données vers  $\{\omega_2\}$  lors de l'étape de réduction des imprécisions.

La figure de Bland et Altman, Figure 6.20, permet d'observer la tendance des méthodes à sur- ou sous-estimer le volume des sphères. Comme nous pouvons le voir, aucune méthode n'offre de bons résultats. Les différences de volume atteignent des valeurs très importantes pour l'ensemble des méthodes, et les valeurs de  $p$  (voir Tableau 6.4) sont très faibles pour la majeure partie des méthodes. Ceci est dû à la nature bruitée des images qui rend la tâche de segmentation difficile, voire impossible pour certaines sphères. En effet, certaines images, trop bruitées, ne permettent pas de distinguer la forme sphérique des sphères. La méthode EVEII<sub>2</sub> semble être la méthode offrant la meilleure estimation des volumes des sphères, avec un biais proche de zéro et une valeur de  $p$  élevée. Cependant, comme nous pouvons le voir Figure 6.20(d), les différences d'estimation sont très largement fonction du contraste. Il y a une importante sur-estimation des volumes pour le contraste  $C_{S/F} = 3,8$  (cercles bleus), et une importante sous-estimation des volumes pour le contraste  $C_{S/F} = 2,7$  (carrés bleus). La méthode commet donc une erreur proportionnelle au contraste, ce qui est une limite importante de la méthode. Les méthodes FLAB et Sad commettent une erreur proportionnelle à la taille des sphères en sous-estimant leur volume. Bien que la méthode EVEII<sub>3 $\beta$</sub>  ait un biais absolu plus important que FLAB ou Sad, elle ne fait pas d'erreur proportionnelle. En outre, elle a

tendance à sur-estimer le volume des sphères, ce qui dans un contexte de radiothérapie externe est moins pénalisant qu'une sous-estimation. Notons que ce sont quelques volumes sur-estimés (Figure 6.20(e)), obtenues pour les sphères les plus difficiles à segmenter (à faible contraste), qui font croître l'écart correspondant à l'indice de concordance.

Les mêmes conclusions peuvent être faites en observant les histogrammes Figure 6.21. Cependant, la figure donne une autre indication concernant la capacité des méthodes à donner le même résultat en fonction des différentes répliques. Comme nous pouvons le voir, avec la méthode  $EVEII_{3\beta}$ , les écart-types pour les contrastes réels 3,3 et 3,8 sont faibles, témoignant de la robustesse de la méthode à offrir un résultat identique pour ces deux contrastes. En revanche, l'écart type est important pour les images de plus faible contraste. Cela donne une indication sur la limite de la méthode. Avec un rapport signal sur bruit d'approximativement 3 (voir Tableau 6.3) et un contraste réel de 2,6, les performances de l'algorithme se dégradent. Il faut un contraste réel au moins supérieur à 3 pour que la mesure du volume soit fiable. La raison est que lorsque le contraste est trop faible, les centroïdes des classes sont mal estimés. Notons que ce même phénomène avait déjà pu être observé sur l'image simulée dans la précédente section, où les performances de  $EVEII_{3\beta}$  chutaient en présence d'un bruit trop important (voir Figures 6.6 et 6.8).

### 6.3.4 Conclusion

Dans cette section, l'évaluation a porté sur la comparaison de notre méthode aux méthodes de la littérature proposées pour la segmentation des images TEP. Deux fantômes ont été utilisés. Le premier fantôme simule les caractéristiques que l'on rencontre en routine clinique lors de l'acquisition d'images TEP au  $^{18}\text{FDG}$  ou à la  $^{18}\text{FLT}$ . Le second, particulièrement bruité, simule les caractéristiques que l'on rencontre avec le traceur  $^{18}\text{FMiso}$ . L'évaluation, sur le premier fantôme, a montré que la méthode  $EVEII_{3\beta}$  était nettement plus performante que les autres méthodes comparées en terme d'erreur d'estimation des volumes. Sur les images de faible rapport signal sur bruit, bien que de larges écarts relatifs aux indices de concordance aient été observés pour l'ensemble des méthodes, c'est la méthode  $EVEII_{3\beta}$  qui semble le plus adaptée à la segmentation des images dans ce contexte particulier. En effet, bien qu'elle sur-estime le volume des sphères, nous avons pu observer Figure 6.19 qu'elle est la plus robuste au bruit et qu'elle ne commet pas d'erreur proportionnelle.

Patient	#1	#2	#3
<b>Données cliniques</b>			
Sexe ({M,F})	M	M	M
Age (ans)	67	48	58
Pathologie	Indifférenciée (T4N2)	Adénocarcinome (TxN3)	Carcinome épidermoïde à non petites cellules (T2N2)
<b>Acquisition</b>			
<i><sup>18</sup>FDG</i>			
Activité administrée (MBq)	325	403	392
Délai après injection (min)	85	72	65
Durée d'acquisition (min)	4,75	3	3
<i><sup>18</sup>FLT</i>			
Activité administrée (MBq)	213	202	274
Délai après injection (min)	76	78	71
Durée d'acquisition (min)	6	5	6
<i><sup>18</sup>FMiso</i>			
Activité administrée (MBq)	291	178	160
Délai après injection (min)	202	211	180
Durée d'acquisition (min)	6	6	7

Tableau 6.5 – Caractéristiques des images TEP au <sup>18</sup>FDG, à la <sup>18</sup>FLT et au <sup>18</sup>FMiso (protocole RTEP4)

## 6.4 Application de la méthode aux images TEP multi-traceurs

Dans cette section, la segmentation des images TEP multi-traceurs, présentée section 5.3, est appliquée. Compte tenu des performances d'EVEII<sub>3β</sub>, cela consiste à appliquer notre méthode sur chacune des images, puis à fusionner les masses de croyance estimées.

### 6.4.1 Matériel et méthodes

#### 6.4.1.1 Données patients

Notre méthode est appliquée sur des images TEP au <sup>18</sup>FDG, à la <sup>18</sup>FLT et au <sup>18</sup>FMiso chez les trois patients de l'essai clinique RTEP4 déjà présenté section 6.3.3.1. Le Tableau 6.5 présente les caractéristiques des images. Pour chacun d'eux, une coupe transverse pour chaque traceur est présentée Figure 6.22. Pour recalcr les images TEP multi-traceurs, un recalage des images TDM, acquises lors de chacun des examens, a préalablement été effectué à partir de l'information mutuelle [Viola et Wells, 1997] en utilisant l'examen TEP-TDM au <sup>18</sup>FDG comme référence. Ensuite, les paramètres de recalage obtenus ont été utilisés pour recalcr les images TEP. Notons que seules les coupes proches de la région tumorale ont été utilisées pour déterminer les paramètres de recalage. Enfin, pour chaque patient, une ROI 3D englobant la lésion tumorale a été manuellement sélectionnée. Chaque ROI a la forme d'un pavé (voir Figure 6.22).



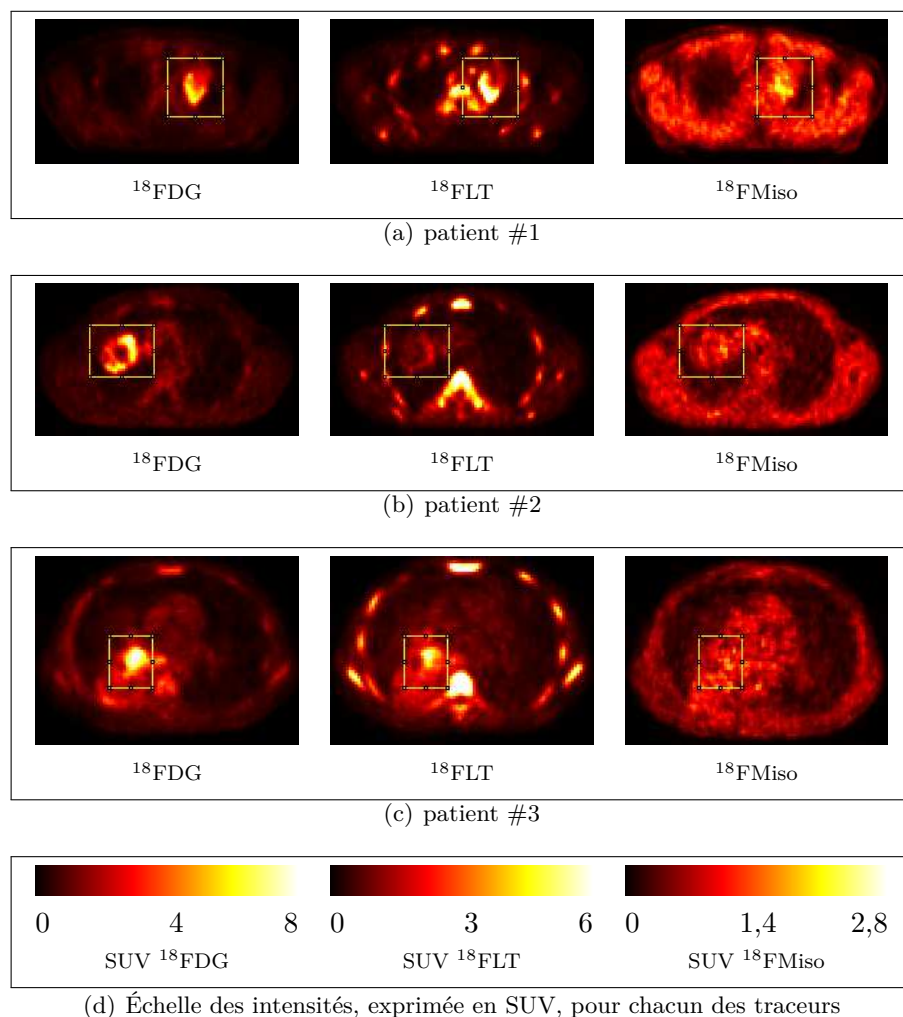


Figure 6.22 – Images TEP au  $^{18}\text{F}$ FDG, à la  $^{18}\text{F}$ FLT et au  $^{18}\text{F}$ Miso chez trois patients de l'étude RTEP4. La Figure (d) correspond à l'échelle des intensités utilisée pour représenter les images correspondant à chaque traceur.

#### 6.4.1.2 Segmentation mono-traceur

Pour estimer les masses de croyance pour chaque image mono-traceur, la méthode  $\text{EVEII}_{3\beta}$  retenue lors de la précédente section a été appliquée sur la ROI 3D.

Jusqu'à présent, cette méthode avait été appliquée sur des données images présentant deux classes homogènes (le fond et l'objet). Lorsqu'on se confronte aux images médicales, cette simplification n'est pas toujours observée. La fixation du traceur dans « le fond », c'est à dire les tissus biologiques autres que tumoraux, n'est pas uniforme et l'hypothèse de départ de la présence de deux classes n'est pas toujours vérifiée. Comme nous pouvons le voir sur l'image TEP au  $^{18}\text{F}$ Miso de la Figure 6.22(a), trois classes sont présentes dans la ROI : les voxels de faible fixation (voxels noirs), les voxels de fixation modérée (voxels rouges) et les voxels de forte fixation (voxels jaunes). Pour palier cet inconvénient, nous proposons d'incorporer à notre méthode un processus itératif, dont l'objectif est de considérer de manière séparée les

voxels étiquetés  $\{\omega_1\}$  et  $\{\omega_2\}$  à chaque itération, en associant à chaque voxel étiquetés  $\{\omega_1\}$  une fonction de masse certaine vis-à-vis de  $\{\omega_1\}$  d'une part, et en ré-exécutant notre algorithme aux voxels étiquetés  $\{\omega_2\}$  d'autre part. Ainsi, même si notre algorithme est exécuté sur seulement deux classes, le processus itératif permet de considérer une classe supplémentaire à chaque itération. Comme l'illustre la Figure 6.23, pour chaque image mono-traceur, cela consiste à ré-exécuter EVEII pour les voxels  $V_i$  respectant la condition :

$$pl_{V_i}(\omega_2) > bel_{V_i}(\omega_1). \quad (6.3)$$

Ils correspondent aux voxels n'appartenant pas, de manière certaine, au fond. Le processus est itéré tant que  $\mu_{\omega_2}$ , la moyenne des intensités des voxels de la classe  $\omega_2$ , est inférieure à une valeur seuil *a priori* exprimée en SUV.  $\mu_{\omega_2}$  est obtenue de la manière suivante à l'issue d'EVEII :

$$\mu_{\omega_2} = \frac{\sum_{i=1}^N SUV_{V_i} \cdot pl_{V_i}(\{\omega_2\})}{\sum_{i=1}^N pl_{V_i}(\{\omega_2\})}. \quad (6.4)$$

Les seuils choisis valent 2,5 pour l'image TEP au  $^{18}\text{FDG}$  et 1,4 pour les images TEP à la  $^{18}\text{FLT}$  et au  $^{18}\text{FMiso}$ . Ces seuils correspondent aux seuils utilisés pour segmenter les différentes images TEP [Nestle *et al.*, 2005; Xu *et al.*, 2011; Rasey *et al.*, 1996], mais ont ici pour seul objectif de permettre de détecter les hyper-fixations dans des milieux hétérogènes.

### 6.4.1.3 Segmentation multi-traceurs

Le processus de fusion, présenté section 5.3, a ensuite été appliqué. Il est schématisé Figure 6.23 et a été appliqué, pour chaque patient, sur la ROI 3D. Pour le patient #3, le processus a également été appliqué sur une ROI 2D (une seule coupe de la ROI 3D). L'objectif étant de montrer l'influence de la définition de la ROI initiale sur le processus de segmentation multi-traceurs.

### 6.4.1.4 Analyse des données

L'analyse des données est réalisée par la visualisation et l'interprétation des images paramétrique obtenues après fusion, ainsi que par le résultat de la segmentation des différents BTV (*Biological Target Volumes*). En effet, il n'existe pas de vérité terrain nous permettant d'évaluer le résultat de la segmentation. La raison est que ces images sont nouvelles et conduisent à des variabilités inter- et intra-opérateur très importantes empêchant une définition fiable de la vérité terrain. En outre, aucune étude ne semble avoir été appliquée à la fusion des images TEP

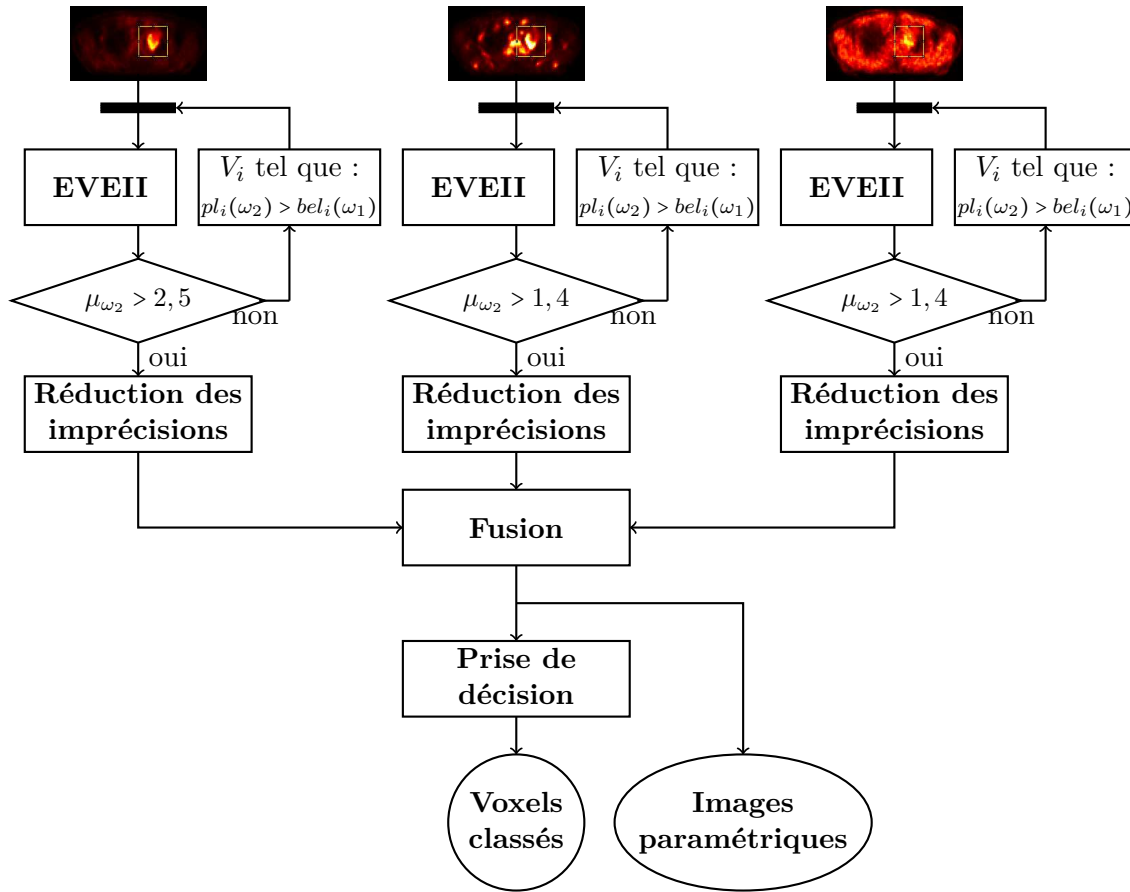


Figure 6.23 – Schéma donnant les différentes étapes de la méthode de segmentation multi-traceurs.

multi-traceurs dans la littérature, empêchant la comparaison de notre méthode avec d'autres méthodes de la littérature.

## 6.4.2 Résultats

### 6.4.2.1 Segmentation mono-traceur

La Figure 6.24 présente la distribution des masses de croyance de chacun des voxels à l'issue de l'étape de réduction des imprécisions pour le patient #1. Comme nous pouvons le voir, de faibles masses de croyance sont affectées à l'hypothèse  $\Omega$ . Ceci est dû au processus de réduction des imprécisions. Ces images permettent de segmenter chaque BTV séparément.

Pour les trois patients, sur les examens au  $^{18}\text{FDG}$  et à la  $^{18}\text{FLT}$ , une seule itération a été nécessaire afin de détecter l'hyper-fixation. Pour le patient #1, sur l'examen au  $^{18}\text{FMiso}$ , deux itérations ont été nécessaires. La Figure 6.25 montre le résultat de l'estimation des croyances avec  $\text{EVEII}_3$  après une, puis deux itérations pour ce patient. Comme nous pouvons le constater, après la première itération, les voxels de faible fixation ( $\{\omega_1\}$ ) sont séparés du reste de l'image

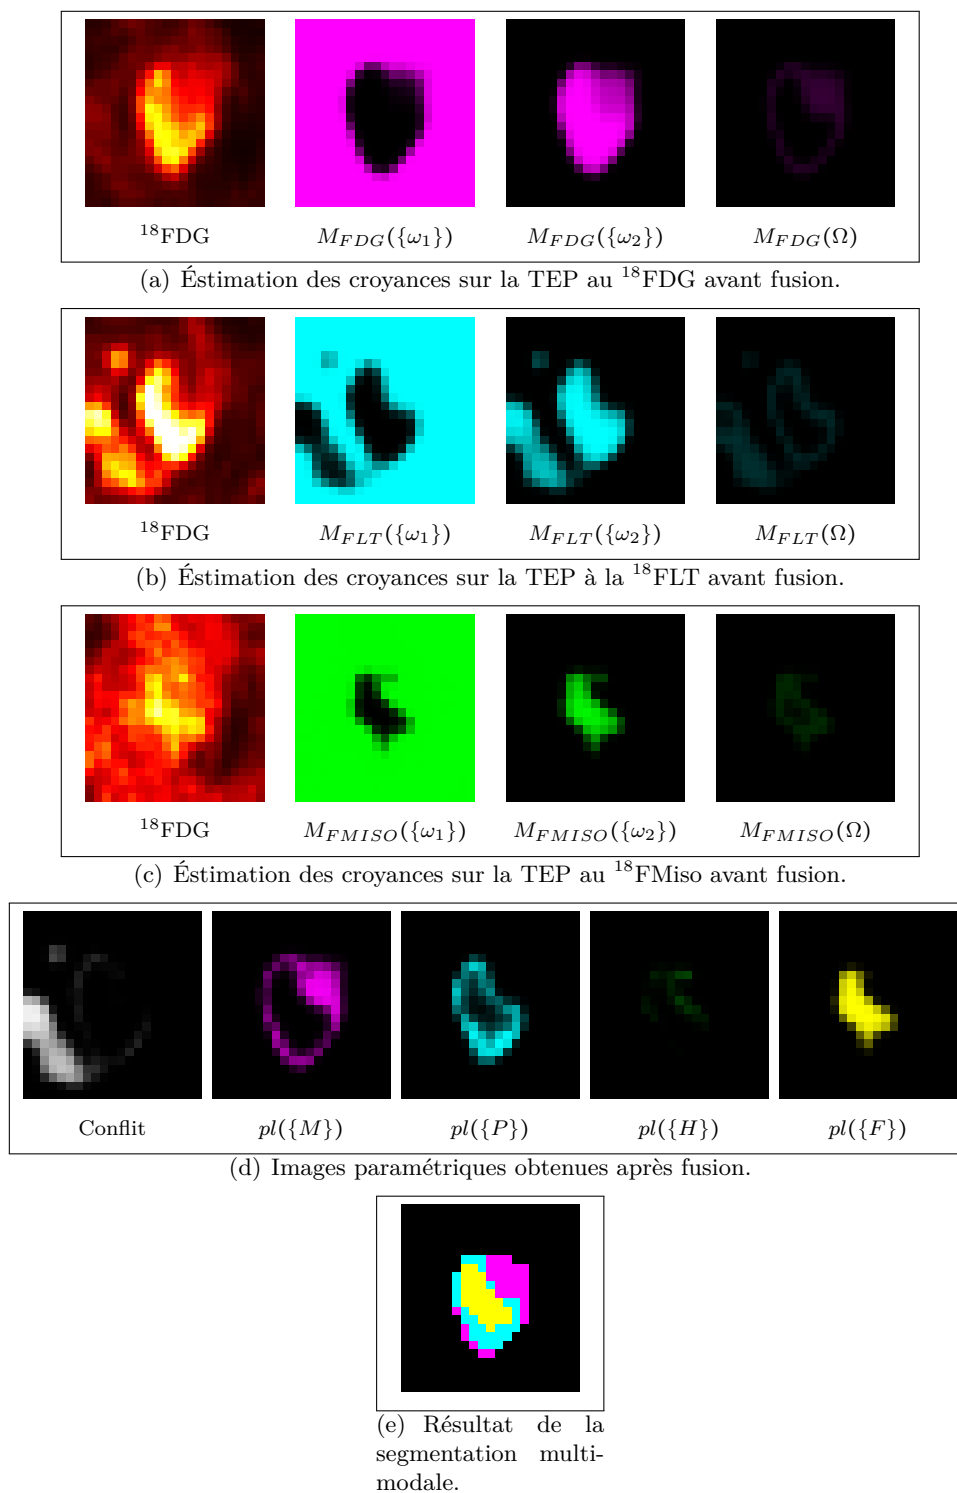




Figure 6.24 – Résultats de la segmentation multimodale chez le patient #1.


( $\{\omega_2\}$  : fixation modérée et hyper-fixation). Après la seconde itération, l'hyper-fixation ( $\{\omega_2\}$ ) a bien été séparée du reste de l'image ( $\{\omega_1\}$  : faible fixation et fixation modérée). Pour les patients #2 et #3, toujours sur l'examen au  $^{18}\text{FMiso}$ , trois itérations ont été nécessaires à la détection de l'hyper-fixation.




(a) Éstimation des croyances après la 1re itération.




(b) Éstimation des croyances après la 2e itération.

Figure 6.25 – Éstimation des croyances sur la TEP au  $^{18}\text{FMiso}$  avec  $\text{EVEII}_{3\beta}$  après une, puis deux itérations.

(a) Images initiales.



(b) Images paramétriques obtenues après fusion.




(c) Résultat de la segmentation multimodale.


Figure 6.26 – Résultats de la segmentation multimodale chez le patient #2.

### 6.4.2.2 Segmentation multi-traceurs


Pour chaque patient, le résultat de la fusion, donnant un ensemble d'images paramétriques, est respectivement donné Figures 6.24(d), 6.26(b) et 6.27(b). De gauche à droite sont représentés le conflit, puis les plausibilités vis à vis des hypothèses  $\{M\}$ ,  $\{P\}$ ,  $\{H\}$ , et  $\{F\}$ . Enfin, le résultat de la segmentation des BTV, à l'issu de la prise de décision, est présenté Figures 6.24(e), 6.26(c) et 6.27(c) pour chaque patient. Pour le patient #1, les résultats montrent que la tumeur présente un hyper-métabolisme glucidique seul important (régions rose), un hyper-métabolisme accompagné d'une forte Prolifération cellulaire (région bleue), et bien qu'il n'y ait pas de région présentant un hyper-métabolisme glucidique accompagné d'une hypoxie (région verte), on remarque que la lésion présente également un hyper-métabolisme glucidique accompagné d'une forte prolifération cellulaire, ainsi que d'une hypoxie (région jaune). Pour le patient #2, la tumeur présente un hyper-métabolisme glucidique seul important, et est accompagnée d'une faible prolifération cellulaire et d'une faible hypoxie. Enfin, pour le patient #3, la tumeur présente un hyper-métabolisme glucidique accompagné d'une forte prolifération cellulaire. Pour ce dernier patient, la segmentation d'une seule coupe 2D faisant apparaître la



(a) Images initiales.



(b) Images paramétriques obtenues après fusion.



(c) Résultat de la segmentation multimodale.

(d) Résultat de la segmentation multimodale sur une seule coupe.

Figure 6.27 – Résultats de la segmentation multimodale chez le patient #3.

lésion est également présentée (voir Figure 6.27(d)). Comme nous pouvons le remarquer, une zone hypoxique, en jaune, est trouvée avec la segmentation en 2D, alors qu'elle est absente avec la segmentation en 3D.

### 6.4.3 Discussion

Tout d'abord, nous avons présenté les résultats de segmentation mono-traceur pour le patient #1 afin d'illustrer le comportement de notre méthode  $EVEII_{3\beta}$ . Elle permet d'estimer les masses de croyance de chaque voxel vis-à-vis de l'hyper-fixation et du fond pour chaque traceur. Un processus itératif y a été incorporé afin de détecter les hyper-fixations en présence d'un fond hétérogène. Nous avons pu remarquer qu'une seule itération avait été effectuée pour les traceurs  $^{18}\text{FDG}$  et  $^{18}\text{FLT}$ . Bien que le processus itératif n'ait pas été nécessaire pour ces deux traceurs, nous l'avons intégré dans l'éventualité où la tumeur présenterait une faible fixation accompagné d'une hétérogénéité dans le fond. Pour les images TEP au  $^{18}\text{FMiso}$  deux itérations ont suffi pour le patient #1, alors que trois itérations ont été nécessaires pour les patients #2 et #3. La raison est que les images TEP au  $^{18}\text{FMiso}$  pour les patients #2 et #3 sont plus bruitées que l'image du patient #1 dont l'activité administrée est bien supérieure (voir Tableau 6.5), conduisant pour les patients #2 et #3 à une plus grande variabilité des intensités dans le fond et donc à une plus grande hétérogénéité.

Nous avons également présenté les résultats de segmentation multi-traceurs pour trois patients de l'étude RTEP4. L'ensemble des images paramétriques, accompagné du résultat de la segmentation, permettent d'observer le caractère fonctionnel des lésions. Les images ont ici pour objectif d'aider le radiothérapeute à mettre en place le traitement par radiothérapie externe, avec potentiellement une escalade de dose des sous-volumes hypoxiques et une augmentation de la fréquence des séances d'irradiation des sous-volumes hyper-prolifératifs à visée de *Dose Painting* [Hall, 2005] (voir section 5.3 page 129).

Elle permet de visualiser les régions dites conflictuelles après fusion, correspondant dans notre étude aux régions présentant une hypoxie et/ou une forte prolifération cellulaire, associée à une normalité vis-à-vis du métabolisme glucidique, qu'il appartient ensuite au médecin d'interpréter médicalement. Pour les trois patients étudiés, un conflit apparaît. Il correspond à des tissus sains de la moelle osseuse pour les patients #1 et #2 présentant une hyper-prolifération physiologique normale bien connue qui n'est pas associée à un hyper-métabolisme glucidique. En revanche, pour le patient #3, le conflit semble avoir pour origine le biais engendré par un problème de recalage de l'image TEP à la  $^{18}\text{FLT}$  sur l'image TEP au  $^{18}\text{FDG}$ . Ainsi, le conflit

peut avoir diverses origines que le médecin pourra interpréter grâce à la modalité anatomique TDM associée au TEP.

Enfin, nous avons présenté Figure 6.27(c) et (d) les résultats de segmentation de BTV, pour le patient #3, en considérant respectivement le volume 3D lésionnel, et une région 2D relative à une coupe. Comme nous pouvons l'observer, l'hypoxie est bien détectée en appliquant la méthode sur la région 2D, mais pas 3D. La non détection de l'hypoxie sur la ROI 3D est due à la proximité entre la lésion et le foie. En effet, sur les coupes précédant celle présentée Figure 6.27(a), la lésion ainsi que le foie sont présents dans la ROI 3D. La concentration d'activité moyenne dans la lésion tumorale est de 840 Bq/mL (voir Tableau 6.2), alors que celle mesurée dans le foie est de 1075 Bq/mL. La présence du foie dans la ROI 3D empêche notre algorithme de détecter l'hypoxie dans la lésion. Sur les images TEP au  $^{18}\text{FDG}$  et à la  $^{18}\text{FLT}$ , la présence du foie a peu d'influence sur le résultat de la segmentation car nous nous retrouvons dans une configuration où l'activité dans le foie est inférieure à l'activité dans la tumeur. Cela montre cependant une limite de la méthode. Avec la définition d'une ROI incluant des tissus sains périphériques dont la concentration d'activité est supérieure à celle de la lésion, la qualité de la segmentation est dégradée. Dans le cadre de la segmentation multi-traceurs de lésions tumorales pulmonaires, ce phénomène peut apparaître dès lors que la lésion est proche du foie pour les trois traceurs, proche du cœur pour le traceur  $^{18}\text{FDG}$  et proche de l'os pour le traceur  $^{18}\text{FLT}$ . Notons cependant que ce phénomène pourra être levé avec la définition d'une ROI ayant une forme géométrique autre que celle d'un pavé, ou en ré-exécutant notre méthode sur les données non conflictuelles.

## 6.5 Conclusion

Dans ce chapitre, nous avons évalué notre méthode, EVEII, sur trois types d'images. Tout d'abord, elle a été évaluée sur des images simulées par comparaison à différentes méthodes proposées pour l'estimation des masses par la théorie des fonctions de croyance. L'étude a montré que notre méthode offre une estimation des croyances mieux adaptée à nos images. En effet, elle permet de réduire l'incertitude au sein des régions bruitées tout en modélisant l'imprécision due à l'effet de volume partiel aux transitions entre les régions. L'évaluation a ensuite portée sur sa capacité à mesurer de façon juste et fidèle les volumes des sphères d'images de fantôme TEP par comparaison à différentes méthodes proposées à cet effet. Les résultats ont montré que notre méthode était plus robuste aux paramètres de taille des sphères, aux différents contrastes, et au bruit. Enfin, les résultats sur les images réelles de trois patients ont



montré que notre méthode était adaptée à la fusion d'images TEP multi-traceurs, offrant à cet effet un ensemble d'images paramétriques d'aide à la segmentation des BTV associée à une stratégie de *Dose Painting*.

Plusieurs variantes de EVEII ont été proposées. Les résultats sur les images simulées ont tout d'abord montré que la méthode EVEII<sub>3</sub> estimait de manière mieux adaptée les croyances que EVEII<sub>1</sub>. Ceci est dû à l'intégration de notre étape de combinaison des informations de voisinage dans l'algorithme itératif FCM. Les résultats sur les images de fantômes ont ensuite montré que lorsque notre méthode de réduction des imprécisions était insérée à notre processus de segmentation, les volumes des sphères sur les images TEP étaient mieux estimés (méthode EVEII<sub>3β</sub>). Sur le second fantôme, la comparaison de EVEII<sub>2</sub> et EVEII<sub>3β</sub> a rapporté que EVEII<sub>3β</sub> était moins sensible aux variations de contraste.

Enfin, quelques limites de la méthode ont été recensées. Nous avons pu remarquer que les performances d'EVEII<sub>3</sub> et d'EVEII<sub>3β</sub> sont légèrement dégradées lorsque la quantité de bruit est importante ou que le contraste est faible. En outre, l'étape de réduction des imprécisions peut être vue comme une limite car elle nécessite un apprentissage sur des données fantômes pour la segmentation des images TEP. Cependant, nous avons pu remarquer que seules les méthodes intégrant ce type d'apprentissage offrent de bonnes performances sur ces images. Enfin, nous avons vu lors de l'étude sur les données patients que la définition manuelle de la ROI, dans laquelle la méthode est exécutée, peut avoir une influence sur le résultat de la segmentation de la tumeur lorsque des tissus sains périphériques présentent une fixation du traceur supérieure à celle de la tumeur. Ainsi, le radiothérapeute devra simplement veiller à exclure ces tissus de la ROI afin d'assurer un résultat reproductible.

# Conclusion et perspectives

## Conclusion

Dans cette thèse, nous avons répondu à la problématique liée à la fusion des images TEP multi-traceurs ( $^{18}\text{FDG}$ ,  $^{18}\text{FLT}$  et  $^{18}\text{FMiso}$ ) dont l'objectif est d'apporter une aide à la planification du traitement par radiothérapie avec une stratégie de *Dose Painting*. Au vu des imperfections contenues dans les images, dues au bruit et à leur faible résolution spatiale, cette tâche est difficile à résoudre. En outre, les images obtenues avec le traceur  $^{18}\text{FMiso}$  présentent un faible rapport signal-sur-bruit, augmentant la difficulté à segmenter les images pour ce traceur. Pour répondre à ces problèmes, nous avons proposé une méthode permettant de faire face à la présence de bruit et d'effet de volume partiel dans les images TEP, dû à la faible résolution spatiale, en vue de les fusionner.

Les études menées en début de chapitre 2 nous ont permis de faire différents constats. Nous avons tout d'abord observé que la majeure partie des méthodes de segmentation en imagerie TEP sont basées sur le seuillage, mais au vu des difficultés que l'on rencontre lors de la segmentation de ces images, de plus en plus d'auteurs s'orientent vers des méthodes basées sur la reconnaissance de formes régies par les théories des probabilités et des ensembles flous. L'intérêt de ces approches est qu'elles ont pour objectif de s'affranchir des imperfections dans les images. Ces imperfections en imagerie TEP sont dues au bruit et à l'effet de volume partiel, et correspondent respectivement à des incertitudes et des imprécisions. Ces deux imperfections, auxquelles une attention toute particulière doit être accordée dans les problèmes de fusion, sont très bien prises en compte dans les méthodes basées sur les théories des possibilités et des fonctions de croyance. Notre choix s'est orienté vers la théorie des fonctions de croyance. Notre attention s'est tout particulièrement portée sur une méthode tirant partie de l'opérateur de combinaison conjonctive pour fusionner les informations de voisinage dans des images médicales. L'intérêt de la méthode est qu'elle permet d'une part d'améliorer la segmentation des voxels sujets au bruit, et d'autre part de détecter les frontières entre les régions où un conflit apparaît, ayant pour origine l'ambiguïté portée par les voxels voisins.

Notre contribution réside dans la proposition d'une méthode, s'appuyant sur la théorie des fonctions de croyance, pour segmenter les images TEP. Des segmentations mono-traceur, puis multi-traceurs sont proposées. Notre méthode de segmentation mono-traceur est composée de

deux étapes principales. La première est nommée EVEII, pour *Evidential Voxel-based Estimation of Imperfect Information*. Elle permet d'estimer les masses de croyance, pour chaque voxel de chaque image, en réduisant l'incertitude due au bruit, tout en modélisant l'imprécision due à la faible résolution spatiale par fusion des informations de voisinage. La deuxième étape concerne la réduction des imprécisions.

Trois variantes de EVEII ont été proposées. Les deux premières, EVEII<sub>1</sub> et EVEII<sub>2</sub>, consistent à estimer les masses de croyances des voxels via l'algorithme Fuzzy C-Means (FCM) et via la mesure d'un Z-score respectivement, puis à appliquer une combinaison disjonctive, suivie d'une combinaison conjonctive des informations de voisinage. Ces combinaisons ont pour effet, d'une part, de réduire les incertitudes due au bruit et, d'autre part, de modéliser l'imprécision à la transition entre les régions. La troisième variante, EVEII<sub>3</sub>, est une modification d'EVEII<sub>1</sub>, dans laquelle la combinaison disjonctive des informations de voisinage est intégrée au sein de l'algorithme FCM. Cela a pour effet de mieux estimer les centroïdes des classes et d'améliorer la classification des voxels.

EVEII<sub>1</sub> et EVEII<sub>3</sub> ont tout d'abord été évaluées sur des images simulées par comparaison à différentes méthodes de la littérature proposées pour l'estimation de masses de croyance dans des environnements imparfaits. Lorsque l'objet est de petite taille par rapport au fond, les résultats sur les images simulées ont montré, visuellement, qu'EVEII<sub>3</sub> est la seule méthode permettant de modéliser l'imprécision à la transition entre les régions, tout en s'affranchissant du bruit. Un objet de petite taille conduit à une inégale répartition des données entre les classes et pose problème pour les autres méthodes. En outre, sur la dernière série d'images évaluée, où le rapport signal-sur-bruit varie entre 1,5 à 5,9, lorsque le rapport est supérieur à 2,5, près de 100 % des pixels sont bien reconnus avec EVEII<sub>3</sub>, contre 98% avec EVEII<sub>1</sub>. Avec les autres méthodes, des taux de reconnaissance bien inférieurs ont été obtenus.

La seconde étape de notre méthode concerne la réduction des imprécisions. Nous avons proposé à cet effet de fusionner la fonction de masse de chaque voxels, obtenue à l'issue d'EVEII, à une fonction de masse simple représentant la quantité de données imprécises devant être réduites sur nos images TEP. Cette quantité, notée  $\beta$ , dépend du contraste et du volume de l'objet à segmenter. Soient EVEII<sub>1 $\beta$</sub>  et EVEII<sub>3 $\beta$</sub>  les deux variantes de notre méthode faisant intervenir la réduction des imprécisions. EVEII<sub>1</sub>, EVEII<sub>1 $\beta$</sub>  et EVEII<sub>3 $\beta$</sub> , ont été comparées sur les images TEP d'un fantôme à trois méthodes de la littérature dédiées à la segmentation des images TEP au <sup>18</sup>FDG. Le fantôme possède les mêmes caractéristiques que les images TEP au <sup>18</sup>FDG et à la <sup>18</sup>FLT. Nous avons observé que notre méthode de réduction des imprécisions apportait une nette amélioration concernant la segmentation des images TEP, avec un pourcen-

tage d'erreur relative absolue moyenne de  $21,4 \pm 9,24$  % pour EVEII<sub>1</sub>, contre  $2,92 \pm 2,4$  % pour EVEII<sub>1 $\beta$</sub>  et  $4,16 \pm 4,76$  % pour EVEII<sub>3 $\beta$</sub> . Ces erreurs sont supérieures à 12 % pour les autres méthodes comparées. Sur les petites sphères, nous avons observé qu'EVEII<sub>3 $\beta$</sub>  estimait nettement mieux les volumes qu'EVEII<sub>1 $\beta$</sub> , avec des pourcentages d'erreur relative absolue moyenne de  $44,2 \pm 37,9$  % pour EVEII<sub>1 $\beta$</sub>  contre  $30,81 \pm 28,13$  pour EVEII<sub>3 $\beta$</sub> . Cela montre encore une fois qu'EVEII<sub>3</sub> est plus performant qu'EVEII<sub>1</sub> face à une inégale répartition des données entre les classes.

Afin d'évaluer notre méthode sur des images TEP simulant le faible rapport signal-sur-bruit que l'on rencontre sur les images TEP au <sup>18</sup>FMiso, les images d'un second fantôme ont été utilisées. Ces images ont pour caractéristique de présenter de très faibles contrastes (de 2,7 à 3,8). L'analyse des volumes a révélé qu'EVEII<sub>3 $\beta$</sub> , par comparaison aux autres méthodes évaluées, estimait le mieux les volumes des sphères avec un biais moyen sur l'estimation du volume de +3,89 mL. Avec les autres méthodes, des biais inférieurs ont été obtenus mais étaient accompagnés d'erreurs proportionnelles au volume des sphères ou au contraste, ce qui est une limite importante des méthodes.

Notre méthode a également été appliquée à la segmentation d'images TEP multi-traceurs chez trois patients. Aucune comparaison à d'autres méthodes n'a été réalisée car il n'existe pas, à notre connaissance, de méthode proposée à cet effet dans la littérature. La segmentation multi-traceurs consiste à appliquer EVEII<sub>3 $\beta$</sub> , suivie de notre méthode de réduction des imprécisions pour chacune des images TEP au <sup>18</sup>FDG, à la <sup>18</sup>FLT et au <sup>18</sup>FMiso, puis de fusionner les trois images par l'intermédiaire de l'opérateur de combinaison conjonctive. Les résultats ont montré que notre méthode était adaptée à la fusion d'images TEP multi-traceurs, offrant à cet effet un ensemble d'images paramétriques permettant de différencier les tissus :

- normaux par rapport au métabolisme glucidique.
- normoxiques sans prolifération cellulaire, mais présentant un hyper-métabolisme glucidique.
- présentant un hyper-métabolisme glucidique associé à une importante prolifération cellulaire.
- présentant un hyper-métabolisme glucidique associé à une hypoxie.
- présentant à la fois un hyper-métabolisme glucidique, une importante prolifération cellulaire et une hypoxie.

En outre, Elle permet de visualiser les régions dites conflictuelles après fusion, correspondant dans notre étude aux régions présentant une hypoxie et/ou une forte prolifération cellulaire, as-

sociée à une normalité vis-à-vis du métabolisme glucidique, qu'il appartient ensuite au médecin d'interpréter médicalement.

## Perspectives

Nous avons proposé une méthode de segmentation d'images que l'on a évalué sur des images simulées et sur des images de fantôme TEP, puis appliqué sur des images de patients pour montrer son intérêt à visée de segmentation des BTV et afin d'envisager un traitement par radiothérapie avec une stratégie de *Dose Painting*. À cet effet, les résultats obtenus sont très encourageant. En guise de perspectives, plusieurs voies pourraient être investiguées. Tout d'abord, nous avons proposé une méthode, basée sur la théorie des fonctions de croyance, tirant partie des opérateurs de combinaison disjonctive et conjonctive pour fusionner les informations de voisinage. Ces opérateurs imposent que les sources à fusionner soient distinctes, ce qui n'est pas nécessairement vérifié. Ainsi, il pourrait être intéressant d'utiliser les opérateurs introduits dans [Denœux, 2008] pour la segmentation de sources ne respectant pas nécessairement cette condition.

Ensuite, l'algorithme FCM, ainsi que la mesure d'un Z-score, ont été utilisés dans EVEII pour estimer les masses de croyance. D'autres méthodes pour l'estimation des fonctions de masse pourraient être utilisées en vue d'améliorer notre méthode.

Notre méthode, EVEII, a été appliquée sur des images simulées d'une part, puis sur des images TEP d'autre part. Son évaluation sur d'autres bases d'images pourraient permettre de valider sa généralité.

La modalité anatomique TDM pourrait être intégrée à notre méthode de fusion. Bien que l'étude des nouveaux traceurs ait un intérêt majeur dans l'avenir du traitement des cancers par radiothérapie, la modalité anatomique n'en reste pas moins la modalité de référence pour la radiothérapie.

Notre méthode de segmentation multi-traceurs a été appliquée sur seulement trois patients. La robustesse de la méthode pourrait être évaluée sur une base de données cliniques plus conséquente, ou sur des images TEP issues d'autres traceurs.

Enfin, le traitement par radiothérapie avec une stratégie de *Dose Painting* est actuellement en cours de validation [Aerts *et al.*, 2010], et l'impact de notre méthode pour la planification du traitement sera évalué.

# Liste des publications Personnelles

## Conférences Internationales avec actes

- B. LELANDAIS, I. GARDIN, L. MOUCHARD, P. VERA et S. RUAN : Segmentation of biological target volumes on multi-tracer pet images based on information fusion for achieving dose painting in radiotherapy. *In 15<sup>th</sup> International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI)*, p. 545–552, Nice, France, 2012a. Lecture Note in Computer Science.
- B. LELANDAIS, I. GARDIN, L. MOUCHARD, P. VERA et S. RUAN : Using belief function theory to deal with uncertainties and imprecisions in image processing. *In Belief Functions*, p. 197–204, Compiègne, France, 2012b. Intelligent and soft computing.

## Conférences Nationales avec actes

- B. LELANDAIS, I. GARDIN, L. MOUCHARD, S. THUREAU, S. RUAN et P. VERA : Modélisation et fusion d'images multi-traceurs TEP par la théorie des fonctions de croyance. *In Recherche en Imagerie et Technologies pour la Santé*, 2011a.
- B. LELANDAIS, I. GARDIN, L. MOUCHARD, P. VERA et S. RUAN : Fusion d'images basée sur la modélisation spatiale d'incertitudes et d'imprécisions par la théorie des fonctions de croyance. *In XXIII<sup>e</sup> colloque GRETSI*, Talence, France, 2011b.

## Article de journal

- B. LELANDAIS, I. GARDIN, L. MOUCHARD, P. VERA et S. RUAN : Dealing with uncertainty and imprecision in image segmentation using belief function theory. *International Journal of Approximate Reasoning (IJAR)*. soumis.

## Résumés soumis à des congrès médicaux internationaux

- J. ANOUAN, B. LELANDAIS, S. RUAN, P. VERA, I. GARDIN et S. HAPDEY :  $^{18}\text{F}$ -fdg-pet partial volume correction using a functional volume and contrast based recovery coefficient approach.

*In European Association of Nuclear Medicine*, Milan, Italy, 2012a.

J. ANOUAN, B. LELANDAIS, S. RUAN, P. VERA, I. GARDIN et S. HAPDEY :  $^{18}\text{F}$ -fdg-pet partial volume correction using a recovery coefficient approach based on functional volume and contrast. *In Society of Nuclear Medicine*, Miami, Florida, 2012b.

B. LELANDAIS, I. GARDIN, S. THUREAU, L. MOUCHARD, B. DUBRAY, S. RUAN et P. VERA : Construction of parametric images to support the segmentation of btv from pet images using belief function theory. *In 2e Molecular Imaging in Radiation Oncology*, p. 32, Vienna, Austria, 2012a.

B. LELANDAIS, I. GARDIN, S. THUREAU, L. MOUCHARD, B. DUBRAY, S. RUAN et P. VERA : Segmentation of  $^{18}\text{F}$ -miso pet images. *In 2e Molecular Imaging in Radiation Oncology*, p. 32, Vienna, Austria, 2012b.

B. LELANDAIS, I. GARDIN, S. THUREAU, L. MOUCHARD, B. DUBRAY, S. RUAN et P. VERA : Segmentation of  $^{18}\text{F}$ -miso pet images. *In Society of Nuclear Medicine*, Miami, Florida, 2012c.

## Résumés soumis à des congrès médicaux nationaux

B. LELANDAIS, I. GARDIN, L. MOUCHARD, P. VERA et S. RUAN : Construction d'images paramétriques d'aide à la délimitation de btv à partir d'images tep par la théorie des fonctions de croyance. *In 22e Congrès national de la Société Française de Radiothérapie Oncologique*, vol. 15, p. 580, Paris, France, 2011a.

B. LELANDAIS, I. GARDIN, L. MOUCHARD, S. THUREAU, B. DUBRAY, S. RUAN et P. VERA : Fusion d'images TEP multitraceurs par la théorie des fonctions de croyance. *In Cancéropôle Nord Ouest*, Deauville, France, 2011b.

S. THUREAU, R. MODZELEWSKI, B. LELANDAIS, A. E. SANSON, I. GARDIN, B. DUBRAY et P. VERA : Analyse quantitative d'images de tep au fluorodésoxyglucose, au fluoromisonidazole et à la fluorothymidine chez cinq patients irradiés pour un cancer bronchique non à petites cellules. *In 22e Congrès national de la Société Française de Radiothérapie Oncologique*, vol. 15, p. 562–563, Paris, France, 2011.

# Bibliographie

- N. B. ABDALLAH, N. M. VOYNEAU et T. DENOËUX : Combining statistical and expert evidence within the d-s framework : Application to hydrological return level estimation. *In Belief Functions*, p. 393–400, 2012.
- M. ABRAMOFF, P. J. MAGALHÃES et S. J. RAM : Image processing with ImageJ. *Biophotonics international*, 11(7) : 36–42, 2004.
- H. J. AERTS, P. LAMBIN et D. D. RUYSSCHER : FDG for dose painting : a rational choice. *Radiother Oncol*, 97(2) : 163–164, Nov 2010.
- M. AMADASUN : A Gaussian mixture model for definition of lung tumor volumes in positron emission tomography. *IEEE Transactions on Systems, Man and Cybernetics*, 19(5) : 1264–1274, Nov 1989.
- V. ANTOINE, B. QUOST, T. DENOËUX et M.-H. MASSON : Evidential clustering with constraints and adaptive metric. *In Workshop on the theory of belief functions*, 2010.
- A. APPRIOU : Formulation et traitement de l'incertain en analyse multi-senseur. *In 14ème Colloque GRETSI*, p. 951–954, Juan-les-Pins, 1993.
- M. ARISTOPHANOUS, B. C. PENNEY, M. K. MARTEL et C. A. PELIZZARI : A Gaussian mixture model for definition of lung tumor volumes in positron emission tomography. *Med Phys*, 34 : 4223–4235, Nov 2007.
- H. ASHAMALLA, S. RAFLA, K. PARIKH, B. MOKHTAR, G. GOSWAMI, S. KAMBAM, H. ABDEL-DAYEM, A. GUIRGUIS, P. ROSS et A. EVOLA : The contribution of integrated PET/CT to the evolving definition of treatment volumes in radiation treatment planning in lung cancer. *Int. J. Radiat. Oncol. Biol. Phys.*, 63 : 1016–1023, Nov 2005.
- M. BACAUSKIENE et A. VERIKAS : The evidence theory based post-processing of colour images. *Informatica*, 15(3) : 315–328, 2004.
- S. BELHASSEN et H. ZAIDI : A novel fuzzy C-means algorithm for unsupervised heterogeneous tumor quantification in PET. *Med Phys*, 37(3) : 1309–1324, Mar 2010.



- S. BEN CHAABANE, M. SAYADI, F. FNAIECH et E. BRASSART : Dempster-shafer evidence theory for image segmentation : Application in cells images. *International Journal of Signal Processing*, 5(2) : 126–132, 2009.
- T. BERGHMANS, M. DUSART, M. PAESMANS, C. HOSSEIN-FOUCHER, I. BUVAT, C. CASTAIGNE, A. SCHERPEREEL, C. MASCAUX, M. MOREAU, M. ROELANDTS, S. ALARD, A. P. MEERT, E. F. PATZ, J. J. LAFITTE et J. P. SCULIER : Primary tumor standardized uptake value (SUVmax) measured on fluorodeoxyglucose positron emission tomography (FDG-PET) is of prognostic value for survival in non-small cell lung cancer (NSCLC) : a systematic review and meta-analysis (MA) by the European Lung Cancer Working Party for the IASLC Lung Cancer Staging Project. *J Thorac Oncol*, 3(1) : 6–12, Jan 2008.
- S. BEUCHER et C. LANTUEJOUL : Use of watersheds in contour detection. *In International Workshop on Image Processing : Real-time Edge and Motion Detection/Estimation*, Rennes, France, 1979.
- J. C. BEZDEK : *Pattern Recognition with Fuzzy Objective Function Algorithms*. Kluwer Academic Publishers, Norwell, MA, USA, 1981.
- Q. C. BLACK, I. S. GRILLS, L. L. KESTIN, C. Y. WONG, J. W. WONG, A. A. MARTINEZ et D. YAN : Defining a radiotherapy target with positron emission tomography. *Int. J. Radiat. Oncol. Biol. Phys.*, 60 : 1272–1282, Nov 2004.
- J. M. BLAND et D. G. ALTMAN : Measuring agreement in method comparison studies. *Stat Methods Med Res*, 8(2) : 135–160, Jun 1999.
- I. BLOCH, J.-P. LE CADRE et H. MAÎTRE : Approches probabilistes et statistiques. *In* I. BLOCH, éd. : *Fusion d'informations en traitement du signal et des images*, Traité IC2, chap. 6, p. 87–118. Hermès, 2003.
- I. BLOCH, N. MILISAVLJEVIC et M. ACHEROY : Multisensor Data Fusion for Saceborne and Airborne Reduction of Mine Suspected Areas. *International Journal of Advanced Robotics Systems*, 4(2) : 173–186, jun 2007.
- I. BLOCH : Information combination operators for data fusion : A comparative review with classification. *IEEE Transactions on Systems, Man and Cybernetics*, 26(1) : 52–67, jan 1996a.
- I. BLOCH : Some aspects of dempster-shafer evidence theory for classification of multi-modality medical images taking partial volume effect into account. *Pattern Recognition Letters*, 17 (8) : 905–919, 1996b.

- I. BLOCH : Defining belief functions using mathematical morphology - application to image fusion under imprecision. *International journal of approximate reasoning*, 48(2) : 437–465, 2008.
- I. BLOCH et H. MAÎTRE : Fuzzy mathematical morphologies : a comparative study. *Pattern recognition*, 28(9) : 1341–1387, 1995.
- R. BOELLAARD, W. J. OYEN, C. J. HOEKSTRA, O. S. HOEKSTRA, E. P. VISSER, A. T. WILLEMSEN, B. ARENDS, F. J. VERZIJLBERGEN, J. ZIJLSTRA, A. M. PAANS, E. F. COMANS et J. PRUIM : The Netherlands protocol for standardisation and quantification of FDG whole body PET studies in multi-centre trials. *Eur. J. Nucl. Med. Mol. Imaging*, 35(12) : 2320–2333, Dec 2008.
- N. BOUSSION, L. CINOTTI, V. BARRA, P. RYVLIN et M. F. : Extraction of epileptogenic foci from pet and spect images by fuzzy modelling and data fusion. *Neuroimage*, 19(3) : 645–654, 2003.
- L. BREIMAN : Bagging predictors. *Machine Learning*, 24(2) : 123–140, 1996.
- L. BREIMAN : Random forests. *Machine Learning*, 45(1) : 5–32, 2001.
- C. B. CALDWELL, K. MAH, Y. C. UNG, C. E. DANJOUX, J. M. BALOGH, S. N. GANGULI et L. E. EHRLICH : Observer variation in contouring gross tumor volume in patients with poorly defined non-small-cell lung tumors on CT : the impact of 18FDG-hybrid PET fusion. *Int. J. Radiat. Oncol. Biol. Phys.*, 51 : 923–931, Nov 2001.
- J. CANNY : A computational approach to edge detection. *IEEE Trans. Pattern Anal. Mach. Intell.*, 8(6) : 679–698, juin 1986.
- A. S. CAPELLE-LAIZE : *Segmentation d'images IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence*. Thèse de doctorat, Université de Poitiers, dec 2003.
- A. S. CAPELLE-LAIZE, O. COLOT et C. FEMANDEZ-MALOIGNE : Introduction of spatial information within the framework of evidence theory. In *IEEE International Conference on Acoustic, Speech and Signal Processing*, vol. 2, p. 785–788, Stockholm, apr 2003.
- A. S. CAPELLE-LAIZE, O. COLOT et C. FEMANDEZ-MALOIGNE : Evidential segmentation scheme of multi-echo mr images for the detection of brain tumors using neighborhood information. *Information Fusion*, 5(3) : 203–216, 2004a.

- A. S. CAPELLE-LAIZE, O. COLOT et C. FEMANDEZ-MALOIGNE : Segmentation of brain tumors by evidence theory : on the use of the conflict information. *In 7th International Conference on Information Fusion*, p. 264–271, Stockholm, 2004b.
- A. S. CAPELLE-LAIZE, C. FEMANDEZ-MALOIGNE et O. COLOT : Tbm for color image processing : a quantization algorithm. *In 9th International Conference on Information Fusion*, p. 1824–1830, 2006.
- G. CELEUX et J. DIEBOLT : L'algorithme SEM : un algorithme d'apprentissage probabiliste : pour la reconnaissance de mélange de densités. *Société de statistique de France*, 34(2) : 35–52, 1986.
- P. CHEEBSUMON, F. H. van VELDEN, M. YAQUB, V. FRINGS, A. J. de LANGEN, O. S. HOEKSTRA, A. A. LAMMERTSMA et R. BOELLAARD : Effects of image characteristics on performance of tumor delineation methods : a test-retest assessment. *J. Nucl. Med.*, 52(10) : 1550–1558, Oct 2011.
- J. L. CHEN, S. R. GUNN, S. NIXON MARK et N. GUNN ROGER : Markov random field models for segmentation of pet images. *In 17th International Conference on Information processing in medical imaging*, vol. 2082, p. 468–474, 2001.
- W. CHEN, T. CLOUGHESY, N. KAMDAR, N. SATYAMURTHY, M. BERGSNEIDER, L. LIAU, P. MISCHEL, J. CZERNIN, M. E. PHELPS et D. H. SILVERMAN : Imaging proliferation in brain tumors with 18F-FLT PET : comparison with 18F-FDG. *J. Nucl. Med.*, 46(6) : 945–952, Jun 2005.
- N. C. CHOI, A. J. FISCHMAN, A. NIEMIERKO, J. S. RYU, T. LYNCH, J. WAIN, C. WRIGHT, P. FIDIAS et D. MATHISEN : Dose-response relationship between probability of pathologic tumor control and glucose metabolic rate measured with FDG PET after preoperative chemoradiotherapy in locally advanced non-small-cell lung cancer. *Int. J. Radiat. Oncol. Biol. Phys.*, 54(4) : 1024–1035, Nov 2002.
- W. CHOI, S. W. LEE, S. H. PARK, J. S. RYU, S. J. OH, K. C. IM, E. K. CHOI, J. H. KIM, S. H. JUNG, S. KIM et S. D. AHN : Planning study for available dose of hypoxic tumor volume using fluorine-18-labeled fluoromisonidazole positron emission tomography for treatment of the head and neck cancer. *Radiother Oncol*, 97 : 176–182, Nov 2010.
- I. F. CIERNIK, E. DIZENDORF, B. G. BAUMERT, B. REINER, C. BURGER, J. B. DAVIS, U. M. LUTOLF, H. C. STEINERT et G. K. VON SCHULTHESS : Radiation treatment planning with

- an integrated positron emission and computer tomography (PET/CT) : a feasibility study. *Int. J. Radiat. Oncol. Biol. Phys.*, 57(3) : 853–863, 2003.
- D. COBZAS, N. BIRKBECK, M. SCHMIDT, M. JÄGERSAND et A. MURTHA : 3d variational brain tumor segmentation using a high dimensional feature set. *In ICCV*, p. 1–8. IEEE, 2007.
- A. COLIN et j.-y. BOIRE : Mri-spect fusion for the synthesis of high resolution 3d functional brain images : a preliminary study. *Computer Methods and Programs in Biomedicine*, 60 (2) : 107–116, 1999.
- A. COLORNI, M. DORIGO et V. MANIEZZO : Distributed Optimization by Ant Colonies. *In European Conference on Artificial Life*, p. In European Conference on Artificial Life (1991), pp. 134–142 Key : citeulike :5791708, 1991.
- J. F. DAISNE, M. SIBOMANA, A. BOL, G. COSNARD, M. LONNEUX et V. GREGOIRE : Evaluation of a multimodality image (CT, MRI and PET) coregistration procedure on phantom and head and neck cancer patients : accuracy, reproducibility and consistency. *Radiother Oncol*, 69 : 237–245, Dec 2003.
- B. DASARATHY : Sensor fusion potential exploitation - innovative architectures and illustrative applications. *Proceedings of the IEEE*, 85(1) : 24–38, jan 1997.
- R. N. DAVÉ : Characterization and detection of noise in clustering. *Pattern Recognition Letters*, 12(11) : 657–664, 1991.
- S. DAVID, D. VISVIKIS, C. ROUX et M. HATT : Multi-observation PET image analysis for patient follow-up quantitation and therapy assessment. *Phys Med Biol*, 56(18) : 5771–5788, Sep 2011.
- S. DAVID, M. HATT, N. BOUSSION, M. ALLARD, D. VISVIKIS, O. BARRETT et P. FERNANDEZ : Multi-tracer PET image fusion using fuzzy theory : a feasibility study. *In IEEE NSC/ MIC 2009 : Nuclear Science Symposium / Medical Imaging Conference*, 2009.
- L. S. DAVIS : A Survey of Edge Detection Techniques. *Computer Graphics Image Processing*, 4 : 248–270, 1975.
- L. F. de GEUS-OEI, D. VRIENS, H. W. van LAARHOVEN, W. T. van der GRAAF et W. J. OYEN : Monitoring and predicting response to therapy with 18F-FDG PET in colorectal cancer : a systematic review. *J. Nucl. Med.*, 50 Suppl 1 : 43S–54S, May 2009.

- A. J. de LANGEN, B. KLABBERS, M. LUBBERINK, R. BOELLAARD, M. D. SPREEUWENBERG, B. J. SLOTMAN, R. de BREE, E. F. SMIT, O. S. HOEKSTRA et A. A. LAMMERTSMA : Re-producibility of quantitative  $^{18}\text{F}$ -3'-deoxy-3'-fluorothymidine measurements using positron emission tomography. *Eur. J. Nucl. Med. Mol. Imaging*, 36(3) : 389–395, Mar 2009.
- M. DEFRISE, P. E. KINAHAN, D. W. TOWNSEND, C. MICHEL, M. SIBOMANA et D. F. NEWPORT : Exact and approximate rebinning algorithms for 3-d pet data. *IEEE Trans. Med. Imaging*, 16(2) : 145–158, 1997.
- A. P. DEMPSTER, N. M. LAIRD et D. B. RUBIN : Maximum Likelihood from Incomplete Data via the EM Algorithm. *Journal of the Royal Statistical Society. Series B (Methodological)*, 39(1) : 1–38, 1977.
- A. DEMPSTER : Upper and lower probabilities induced by a multivalued mapping. *Annals of Mathematical Statistics*, 38(2) : 325–339, 1967.
- T. DENOËUX et M. H. MASSON : EVCLUS : evidential clustering of proximity data. *IEEE Trans Syst Man Cybern B Cybern*, 34 : 95–109, Feb 2004.
- T. DENOËUX : An evidence-theoretic neural network classifier. *IEEE International Conference on Systems, Man and Cybernetics*, 25(1) : 712–717, oct 1995a.
- T. DENOËUX : A  $k$ -nearest neighbor classification rule based on dempster-shafer theory. *IEEE transactions on systems, man, and cybernetics*, 25(5) : 804–813, 1995b.
- T. DENOËUX : Analysis of evidence-theoretic decision rules for pattern classification. *Pattern Recognition*, 30(7) : 1095–1107, 1997a.
- T. DENOËUX : A neural network classifier based on dempster-shafer theory. *IEEE International Conference on Systems, Man and Cybernetics*, 30(2) : 131–150, mar 2000.
- T. DENOËUX : Conjunctive and disjunctive combination of belief functions induced by nondistinct bodies of evidence. *Artif. Intell.*, 172(2-3) : 234–264, 2008.
- T. DENOËUX : Maximum likelihood estimation from uncertain data in the belief function framework. *IEEE Transactions on Knowledge and Data Engineering*, 25(1) : 119–130, 2013.
- T. DENOËUX et G. GOVAERT : Combined supervised and unsupervised learning for system diagnosis using dempster-shafer theory. *In CESA'96 IMACS Multiconference*, p. 104–109, 1996.

- T. DENOEU et M.-H. MASSON, éd. *Belief Functions : Theory and Applications - Proceedings of the 2nd International Conference on Belief Functions, Compiègne, France, 9-11 May 2012*, vol. 164 de *Advances in Soft Computing*, 2012. Springer.
- A. S. DEWALLE-VIGNION, N. BETROUNI, R. LOPES, D. HUGLO, S. STUTE et M. VERMANDEL : A New Method for Volume Segmentation of PET Images, Based on Possibility Theory. *IEEE Trans Med Imaging*, 30 : 409–423, Feb 2011.
- S. DISCHE, M. I. SAUNDERS, C. WILLIAMS, A. HOPKINS et E. AIRD : Precision in reporting the dose given in a course of radiotherapy. *Radiother Oncol*, 29(3) : 287–293, Dec 1993.
- W. DOU, S. RUAN, Y. CHEN, D. BLOYET et J.-M. CONSTANS : A framework of fuzzy information fusion for the segmentation of brain tumor tissues on mr images. *Image Vision Comput.*, 25(2) : 164–171, 2007.
- L. A. DREVER, W. ROA, A. MCEWAN et D. ROBINSON : Comparison of three image segmentation techniques for target volume delineation in positron emission tomography. *J Appl Clin Med Phys*, 8 : 93–109, 2007.
- A. DROMIGNY-BADIN, S. ROSSATO et Y. ZHU : Fusion de données radioscopiques et ultrasonores via la théorie de l'évidence. *Traitement du Signal*, 14(5) : 499–510, 1997.
- D. DUBOIS et H. PRADE : *Théorie des possibilités*. Masson, 1987.
- D. DUBOIS et H. PRADE : Representation and combination of uncertainty with belief functions and possibility measures. *Computational Intelligence*, 4 : 244–264, 1988.
- D. DUBOIS et H. PRADE : Consonant approximation of belief functions. *Int. J. Approx. Reasoning*, 4(5-6) : 419–449, 1990.
- M. DUMONT, R. MARÉE, P. GEURTS et L. WEHENKEL : Random subwindows and multiple output decision trees for generic image annotation. *In 16th Annual Machine Learning Conference of Belgium and The Netherlands, Poster*, 2007.
- M. ELAD : On the origin of the bilateral filter and ways to improve it. *IEEE Transactions on Image Processing*, 1(10) : 1141–1151, Nov 2002.
- B. EMAMI, J. LYMAN, A. BROWN, L. COIA, M. GOITEIN, J. E. MUNZENRIDER, B. SHANK, L. J. SOLIN et M. WESSON : Tolerance of normal tissue to therapeutic irradiation. *Int. J. Radiat. Oncol. Biol. Phys.*, 21(1) : 109–122, May 1991.

- Y. E. ERDI, O. MAWLAWI, S. M. LARSON, M. IMBRIACO, H. YEUNG, R. FINN et J. L. HUMM : Segmentation of lung lesion volume by adaptive positron emission tomography image thresholding. *Cancer*, 80 : 2505–2509, Dec 1997.
- K. ERLANDSSON, I. BUVAT, P. H. PRETORIUS, B. A. THOMAS et B. F. HUTTON : A review of partial volume correction techniques for emission tomography and their applications in neurology, cardiology and oncology. *Phys Med Biol*, 57(21) : R119–159, Nov 2012.
- S. M. ESCHMANN, F. PAULSEN, C. BEDESHEM, H. J. MACHULLA, T. HEHR, M. BAMBERG et R. BARES : Hypoxia-imaging with (18)F-Misonidazole and PET : changes of kinetics during radiotherapy of head-and-neck cancer. *Radiother Oncol*, 83 : 406–410, Jun 2007.
- S. M. ESCHMANN, F. PAULSEN, M. REIMOLD, H. DITTMANN, S. WELZ, G. REISCHL, H. J. MACHULLA et R. BARES : Prognostic impact of hypoxia imaging with 18F-misonidazole PET in non-small cell lung cancer and head and neck cancer before radiotherapy. *J. Nucl. Med.*, 46(2) : 253–260, Feb 2005.
- J. M. ESNAULT, M. VERMANDEL, F. MORSCHHAUSER, M. STEINLING et H. D. : Use of pet volume determination by fuzzy logic in the follow up of lymphomas treated by radio-immunotherapy. *Med. Nucl.*, 31(12) : 656–664, 2007.
- E. C. FORD, J. HERMAN, E. YORKE et R. L. WAHL : 18F-FDG PET/CT for image-guided and intensity-modulated radiotherapy. *J. Nucl. Med.*, 50 : 1655–1665, Oct 2009.
- J. L. FOX, R. RENGAN, W. O’MEARA, E. YORKE, Y. ERDI, S. NEHMEH, S. A. LEIBEL et K. E. ROSENZWEIG : Does registration of PET and planning CT images decrease interobserver and intraobserver variation in delineating tumor volumes for non-small-cell lung cancer? *Int. J. Radiat. Oncol. Biol. Phys.*, 62(1) : 70–75, May 2005.
- Y. FREUND et R. E. SCHAPIRE : Experiments with a new boosting algorithm. *In International Conference on Machine Learning*, p. 148–156, 1996.
- V. FRINGS, A. J. de LANGEN, E. F. SMIT, F. H. van VELDEN, O. S. HOEKSTRA, H. van TINTEREN et R. BOELLAARD : Repeatability of metabolically active volume measurements with 18F-FDG and 18F-FLT PET in non-small cell lung cancer. *J. Nucl. Med.*, 51(12) : 1870–1877, Dec 2010.
- B. GAGEL, P. REINARTZ, E. DIMARTINO, M. ZIMNY, M. PINKAWA, P. MANESCHI, S. STANZEL, K. HAMACHER, H. H. COENEN, M. WESTHOFEN, U. BULL et M. J. EBLE : pO(2)

- Polarography versus positron emission tomography ([ $^{18}\text{F}$ ] fluoromisonidazole, [ $^{18}\text{F}$ ]-2-fluoro-2'-deoxyglucose). An appraisal of radiotherapeutically relevant hypoxia. *Strahlenther Onkol*, 180(10) : 616–622, Oct 2004.
- P. E. GALAVIS, C. HOLLENSSEN, N. JALLOW, B. PALIWAL et R. JERAJ : Variability of textural features in FDG PET images due to different acquisition modes and reconstruction parameters. *Acta Oncol*, 49(7) : 1012–1016, Oct 2010.
- L. GAUTIER, A. TALEB-AHMED, M. ROMBAUT, J. G. POSTAIRE et H. LECLET : Aide à la décision de segmentation d'image par la théorie de dempster-shafer : application à une séquence d'images irm. *ITBM-RBM*, 22(6) : 378–392, 1999.
- X. GEETS, J. A. LEE, A. BOL, M. LONNEUX et V. GREGOIRE : A gradient-based method for segmenting FDG-PET images : methodology and validation. *Eur. J. Nucl. Med. Mol. Imaging*, 34 : 1427–1438, Sep 2007.
- A. J. GREEN, R. J. FRANCIS, S. BAIG et R. H. BEGENT : Semiautomatic volume of interest drawing for ( $^{18}\text{F}$ )-FDG image analysis-method and preliminary results. *Eur. J. Nucl. Med. Mol. Imaging*, 35 : 393–406, Feb 2008.
- T. GUPTA, S. JAIN, J. P. AGARWAL, V. RANGARAJAN, N. PURANDARE, S. GHOSH-LASKAR et K. A. DINSHAW : Diagnostic performance of response assessment FDG-PET/CT in patients with head and neck squamous cell carcinoma treated with high-precision definitive (chemo)radiation. *Radiother Oncol*, 97(2) : 194–199, Nov 2010.
- R. HAASE, V. HIETSCHOLD, M. ANDREEFF, H.-J. BÖHME et N. ABOLMAALI : A new segmentation algorithm for low contrast positron emission tomography based on ant colony optimization. In *Crossing the Borders with ABC, Automation, Biomedical Engineering and Computer Science*, p. 501–505, Ilmenau, Germany, 2010. Proceedings of the 55th IWK, TU.
- G. HAIYING, K. TOSHIRO, H. XIAOLEI, S. Z. XIANG et M. TURK : Automatic hot spot detection and segmentation in whole body fdg-pet images. In *IEEE International Conference on Image Processing*, p. 85–88, Atlanta, GA, 2006.
- E. J. HALL : Dose-painting by numbers : a feasible approach? *Lancet Oncol.*, 6(2) : 66, Feb 2005.
- L. M. HAMBERG, G. J. HUNTER, N. M. ALPERT, N. C. CHOI, J. W. BABICH et A. J. FISCHMAN : The dose uptake ratio as an index of glucose metabolism : useful parameter or oversimplification? *J. Nucl. Med.*, 35 : 1308–1312, Aug 1994.



- D. HAN, J. YU, Y. YU, G. ZHANG, X. ZHONG, J. LU, Y. YIN, Z. FU, D. MU, B. ZHANG, W. HE, Z. HUO, X. LIU, L. KONG, S. ZHAO et X. SUN : Comparison of (18)F-fluorothymidine and (18)F-fluorodeoxyglucose PET/CT in delineating gross tumor volume by optimal threshold in patients with squamous cell carcinoma of thoracic esophagus. *Int. J. Radiat. Oncol. Biol. Phys.*, 76 : 1235–1241, Mar 2010.
- X. HAN, M. S. HOOGEMAN, P. C. LEVENDAG, L. S. HIBBARD, D. N. TEGUH, P. VOET, A. C. COWEN et T. K. WOLF : Atlas-based auto-segmentation of head and neck CT images. *Med Image Comput Comput Assist Interv*, 11 : 434–441, 2008.
- G. E. HANKS, S. A. LEIBEL, J. M. KRALL et S. KRAMER : Patterns of care studies : dose-response observations for local control of adenocarcinoma of the prostate. *Int J Radiat Oncol Biol Phys*, 11(1) : 153–7, 1985.
- R. M. HARALICK, DINSTEIN et K. SHANMUGAM : Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6) : 610–621, 1973.
- M. HATT, C. Cheze le REST, P. DESCOURT, A. DEKKER, D. DE RUYSSCHER, M. OELLERS, P. LAMBIN, O. PRADIER et D. VISVIKIS : Accurate automatic delineation of heterogeneous functional volumes in positron emission tomography for oncology applications. *Int. J. Radiat. Oncol. Biol. Phys.*, 77(1) : 301–308, May 2010a.
- M. HATT, C. CHEZE-LE REST, E. ABOAGYE, O., L. KENNY, M., L. ROSSO, F. TURKHEIMER, E., N. ALBARGHACH, M., J.-P. METGES, O. PRADIER et D. VISVIKIS : Reproducibility of  $^{18}\text{f}$ -fdg and 3'-deoxy-3'- $^{18}\text{f}$ -fluorothymidine pet tumor volume measurements. *Journal of nuclear medicine : official publication, Society of Nuclear Medicine*, 51(9) : 1368–76, sept. 2010b.
- M. HATT, C. Cheze le REST, A. TURZO, C. ROUX et D. VISVIKIS : A fuzzy locally adaptive bayesian segmentation approach for volume determination in pet. *IEEE Transactions on Medical Imaging*, 28(6) : 881–893, 2008.
- M. HATT, F. LAMARE, N. BOUSSION, A. TURZO, C. COLLET, F. SALZENSTEIN, C. ROUX, P. JARRITT, K. CARSON, C. CHEZE-LE-REST et D. VISVIKIS : Fuzzy hidden markov chains segmentation for volume determination and quantitation in pet. *Physics in Medicine and Biology*, 52(12) : 3467–3491, 2007.
- T. R. HENRY, K. A. FREY, J. C. SACKELLARES, S. GILMAN, R. A. KOEPPE, J. A. BRUNBERG, D. A. ROSS, S. BERENT, A. B. YOUNG et D. E. KUHL : In vivo cerebral metabolism and

- central benzodiazepine-receptor binding in temporal lobe epilepsy. *Neurology*, 43(10) : 1998–2006, Oct 1993.
- K. HERRMANN, K. OTT, A. K. BUCK, F. LORDICK, D. WILHELM, M. SOUVATZOGLOU, K. BECKER, T. SCHUSTER, H. J. WESTER, J. R. SIEWERT, M. SCHWAIGER et B. J. KRAUSE : Imaging gastric cancer with PET and the radiotracers 18F-FLT and 18F-FDG : a comparative analysis. *J. Nucl. Med.*, 48(12) : 1945–1950, Dec 2007.
- T. K. HO : The random subspace method for constructing decision forests. *IEEE Trans. Pattern Anal. Mach. Intell.*, 20(8) : 832–844, 1998.
- S. HU, E. A. HOFFMAN et J. M. REINHARDT : Automatic lung segmentation for accurate quantitation of volumetric X-ray CT images. *IEEE Trans Med Imaging*, 20 : 490–498, Jun 2001.
- H. M. HUDSON et R. S. LARKIN : Accelerated image reconstruction using ordered subsets of projection data. *IEEE Trans Med Imaging*, 13 : 601–609, 1994.
- M. A. HURN, K. V. MARDIA, T. J. HAINSWORTH, J. KIRKBRIDE et E. BERRY : Bayesian fused classification of medical images. *IEEE Trans Med Imaging*, 15(6) : 850–858, 1996.
- Y. ICHIYA, Y. KUWABARA, M. SASAKI, T. YOSHIDA, J. OMAGARI, Y. AKASHI, A. KAWASHIMA, T. FUKUMURA et K. MASUDA : A clinical evaluation of FDG-PET to assess the response in radiation therapy for bronchogenic carcinoma. *Ann Nucl Med*, 10(2) : 193–200, May 1996.
- A. K. JAIN, M. N. MURTY et P. J. FLYNN : Data clustering : a review. *ACM Comput. Surv.*, 31 : 264–323, September 1999.
- W. JENTZEN, L. FREUDENBERG, E. G. EISING, M. HEINZE, W. BRANDAU et A. BOCKISCH : Segmentation of PET volumes by iterative image thresholding. *J. Nucl. Med.*, 48(1) : 108–114, Jan 2007.
- I. JRAIDI et Z. ELOUEDI : Belief classification approach based on generalized credal em. *Lecture Notes in Computer Science*, 4724 : 524–535, 2007.
- S. I. KAMATA, R. O. EASON et Y. BANDO : A new algorithm for N-dimensional Hilbert scanning. *IEEE Trans Image Process*, 8(7) : 964–973, 1999.
- C. KAMPHUIS, F. BEEKMAN et M. VIERGEVER : Evaluation of os-em vs ml-em for 1d, 2d and fully 3d spect reconstruction iee trans. nucl. sci. *IEEE Trans. Nucl. Sci.*, 43 : 2018–2024, 1996.

- R. KENNES et P. SMETS : Computational aspects of the mobius transformation. *In UAI '90 : Proceedings of the Sixth Annual Conference on Uncertainty in Artificial Intelligence*, p. 401–416, New York, NY, USA, 1991. Elsevier Science Inc.
- Y. KESSENTINI : *Modèles de Markov multi-flux pour la reconnaissance de l'écriture manuscrite multi-scripts*. Thèse de doctorat, Université de Rouen, Rouen, France, may 2009.
- J. KLEIN : *Suivi robuste d'objets dans les séquences d'images par fusion de sources, application au suivi de véhicules dans les scènes routières*. Thèse de doctorat, Université de Rouen, Rouen, France, dec 2008.
- W. J. KOH, K. S. BERGMAN, J. S. RASEY, L. M. PETERSON, M. L. EVANS, M. M. GRAHAM, J. R. GRIERSON, K. L. LINDSLEY, T. K. LEWELLEN et K. A. KROHN : Evaluation of oxygenation status during fractionated radiotherapy in human nonsmall cell lung cancers using [F-18]fluoromisonidazole positron emission tomography. *Int. J. Radiat. Oncol. Biol. Phys.*, 33(2) : 391–398, Sep 1995.
- J. KOHLAS et P.-A. MONNEY : A mathematical theory of hints : an approach to the dempster-shafer theory of evidence. *Lecture notes in economics and mathematical systems*, 425, 1995.
- T. KROHN, H. J. KAISER, B. GAGEL, C. BOY, W. M. SCHAEFER, U. BUELL et M. ZIMNY : [3D volume and SUV analysis of oncological PET studies : a voxel-based image processing tool with NSCLC as example]. *Nuklearmedizin*, 46 : 141–148, 2007.
- J. S. KROUWER : Why Bland-Altman plots should use X, not  $(Y+X)/2$  when X is a reference method. *Stat Med*, 27(5) : 778–780, Feb 2008.
- K. LANGE et R. CARSON : EM reconstruction algorithms for emission and transmission tomography. *J Comput Assist Tomogr*, 8 : 306–316, Apr 1984.
- S. LE HÉGARAT-MASCLE, I. BLOCH et D. VIDAL-MADJAR : Application of Dempster-Shafer Evidence Theory to Unsupervised Classification in Multisource Remote Sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 35(4) : 1018–1031, 1997.
- M. LECCHI, P. FOSSATI, F. ELISEI, R. ORECCHIA et G. LUCIGNANI : Current concepts on imaging in radiotherapy. *Eur J Nucl Med Mol Imaging*, 35(4) : 821–37, 2008.
- N. Y. LEE, J. G. MECHALAKOS, S. NEHMEH, Z. LIN, O. D. SQUIRE, S. CAI, K. CHAN, P. B. ZANZONICO, C. GRECO, C. C. LING, J. L. HUMM et H. SCHODER : Fluorine-18-labeled fluoromisonidazole positron emission and computed tomography-guided intensity-modulated

- radiotherapy for head and neck cancer : a feasibility study. *Int. J. Radiat. Oncol. Biol. Phys.*, 70 : 2–13, Jan 2008.
- B. LELANDAIS, C. DÉSIR, C. PETITJEAN, L. HEUTTE et L. THIBERVILLE : Classification d'images alvéoscopiques par extra-trees. *In RFIA*, Caen, France, Jan 2010.
- C. C. LING, J. HUMM, S. LARSON, H. AMOLS, Z. FUKS, S. LEIBEL et J. A. KOUTCHER : Towards multidimensional radiotherapy (MD-CRT) : biological imaging and biological conformality. *Int. J. Radiat. Oncol. Biol. Phys.*, 47 : 551–560, Jun 2000.
- M. MAC MANUS et R. HICKS : The use of positron emission tomography (pet) in the staging/evaluation, treatment, and follow-up of patients with lung cancer : a critical review. *Int. J. Radiat. Oncol. Biol. Phys.*, 72(5) : 1298–1306, 2008.
- M. P. MAC MANUS, R. J. HICKS, J. P. MATTHEWS, A. MCKENZIE, D. RISCHIN, E. K. SALMINEN et D. L. BALL : Positron emission tomography is superior to computed tomography scanning for response-assessment after radical radiotherapy or chemoradiotherapy in patients with non-small-cell lung cancer. *J. Clin. Oncol.*, 21(7) : 1285–1292, Apr 2003.
- M. MACMANUS, M. BAYNE, N. FIMMELL, J. REYNOLDS, S. EVERITT, D. BALL, A. PITMAN, R. WARE, E. LAU et R. HICKS<sup>1</sup> : Reproducibility of intelligent contouring of gross tumor volume in non-small cell lung cancer on pet/ct images using a standardized visual method. *International Journal of Radiation Oncology\*Biology\*Physics*, 69(3) : 154–155, nov 2007.
- M. MACMANUS et R. HICKS : Where do we draw the line? contouring tumors on positron emission tomography/computed tomography. *International Journal of Radiation Oncology\*Biology\*Physics*, 71(1) : 2–4, may 2008.
- J. B. MACQUEEN : Some methods for classification and analysis of multivariate observations. *In* L. M. L. CAM et J. NEYMAN, édés : *Proc. of the fifth Berkeley Symposium on Mathematical Statistics and Probability*, vol. 1, p. 281–297. University of California Press, 1967.
- J. B. MAINTZ et M. A. VIERGEVER : A survey of medical image registration. *Med Image Anal.*, 2(1) : 1–36, Mar 1998.
- N. MAKNI, N. BETROUNI et O. COLOT : Introducing spatial neighbourhood in evidential c-means for segmentation of multi-source images : application to prostate multi-parametric mri. *Information Fusion*, 2012. in press.
- A. MARTIN : La fusion d'informations. Rap. tech., Polycopié de cours ENSIETA, 2005.

- M.-H. MASSON et T. DENŒUX : Clustering interval-valued proximity data using belief functions. *Pattern Recogn. Lett.*, 25(2) : 163–171, 2004.
- M.-H. MASSON et T. DENŒUX : ECM : An evidential version of the fuzzy c-means algorithm. *Pattern Recognition*, 341(4) : 1384–1397, 2008.
- H. MATSUDA, S. MIZUMURA, T. NAGAO, T. OTA, T. IZUKA, K. NEMOTO, N. TAKEMURA, H. ARAI et A. HOMMA : Automated discrimination between very early Alzheimer disease and controls using an easy Z-score imaging system for multicenter brain perfusion single-photon emission tomography. *AJNR Am J Neuroradiol*, 28(4) : 731–736, Apr 2007.
- MICAD : [18f]fluoromisonidazole. Bethesda (MD) : National Center for Biotechnology Information (US), 2005.
- J. MONTAGNER, V. BARRA et J.-Y. BOIRE : Modeling of a multimodal image aggregation process using discrete geometry. *In First Open International Conference on Modelling and Simulation*, juin 2005.
- J. MONTAGNER, V. BARRA et J.-Y. BOIRE : A geometrical approach to multiresolution management in the fusion of digital images. *Lecture Notes in Computer Sciences*, 4370 : 121–136, mai 2007.
- D. W. MONTGOMERY, A. AMIRA et H. ZAIDI : Fully automated segmentation of oncological PET volumes using a combined multiscale and statistical model. *Med Phys*, 34 : 722–736, Feb 2007.
- C. MULLER, M. ROMBAUT et M. JANIER : Dempster shafer approach for high level data fusion applied to the assessment of myocardial viability. *In Proceedings of the First International Workshop on Functional Imaging and Modeling of the Heart*, p. 104–112, London, UK, 2001. Springer-Verlag.
- S. A. NEHMEH, N. Y. LEE, H. SCHRODER, O. SQUIRE, P. B. ZANZONICO, Y. E. ERDI, C. GRECO, G. MAGERAS, H. S. PHAM, S. M. LARSON, C. C. LING et J. L. HUMM : Reproducibility of intratumor distribution of (18)F-fluoromisonidazole in head and neck cancer. *Int. J. Radiat. Oncol. Biol. Phys.*, 70 : 235–242, Jan 2008.
- U. NESTLE, S. KREMP, A. SCHAEFER-SCHULER, C. SEBASTIAN-WELSCH, D. HELLWIG, C. RUBE et C. M. KIRSCH : Comparison of different methods for delineation of 18F-FDG PET-positive tissue for target volume definition in radiotherapy of patients with non-Small cell lung cancer. *J. Nucl. Med.*, 46 : 1342–1348, Aug 2005.

- A. C. PAULINO et P. A. JOHNSTONE : FDG-PET in radiotherapy treatment planning : Pandora's box? *Int. J. Radiat. Oncol. Biol. Phys.*, 59 : 4–5, May 2004.
- W. PIECZYNSKI : Modèles de Markov en traitement d'images = Markov models in image processing. *Traitement du Signal*, 20(3) : 255–278, 2003.
- B. PIETROPAOLI, M. DOMINICI et F. WEIS : Belief inference with timed evidence - methodology and application using sensors in a smart home. *In Belief Functions*, p. 409–416, 2012.
- V. POTESIL, X. HUANG et X. S. ZHOU : Automated Tumour Delineation Using Joint PET/CT Information. *In Proc. Of SPIE, Medical Imaging : Computer-aided Diagnosis*, vol. 6514, 2007.
- J. M. S. PREWITT : Object enhancement and extraction. *In B. LIPKIN et A. ROSENFELD*, édés : *Picture Processing and Psychopictorics*, p. 75–149. New York Academic Press, 1970.
- E. PRIETO, P. LECUMBERRI, M. PAGOLA, M. GOMEZ, I. BILBAO, M. ECAY, I. PENUELAS et J. M. MARTI-CLIMENT : Twelve automated thresholding methods for segmentation of PET images : a phantom study. *Phys Med Biol*, 57(12) : 3963–3980, Jun 2012.
- L. R. RABINER : Readings in speech recognition. chap. A tutorial on hidden Markov models and selected applications in speech recognition, p. 267–296. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 1990.
- J. G. RAJENDRAN, K. R. HENDRICKSON, A. M. SPENCE, M. MUZI, K. A. KROHN et D. A. MANKOFF : Hypoxia imaging-directed radiation treatment planning. *Eur. J. Nucl. Med. Mol. Imaging*, 33 Suppl 1 : 44–53, Jul 2006.
- J. G. RAJENDRAN, D. C. WILSON, E. U. CONRAD, L. M. PETERSON, J. D. BRUCKNER, J. S. RASEY, L. K. CHIN, P. D. HOFSTRAND, J. R. GRIERSON, J. F. EARY et K. A. KROHN : [(18)F]FMISO and [(18)F]FDG PET imaging in soft tissue sarcomas : correlation of hypoxia, metabolism and VEGF expression. *Eur. J. Nucl. Med. Mol. Imaging*, 30(5) : 695–704, May 2003.
- E. RAMASSO : *Reconnaissance de séquences d'états par le Modèle des Croyances Transférables Application à l'analyse de vidéos d'athlétisme*. Thèse de doctorat, Université Joseph Fourier, Grenoble, France, dec 2007.
- E. RAMASSO, M. ROMBAUT et D. PELLERIN : Modèle des croyances transférables : Représentation des connaissances, fusion d'informations, décision. Rap. tech., Université Joseph Fourier de Grenoble, 2007.

- J. S. RASEY, W. J. KOH, M. L. EVANS, L. M. PETERSON, T. K. LEWELLEN, M. M. GRAHAM et K. A. KROHN : Quantifying regional hypoxia in human tumors with positron emission tomography of [18F]fluoromisonidazole : a pretherapy study of 37 patients. *Int. J. Radiat. Oncol. Biol. Phys.*, 36(2) : 417–428, Sep 1996.
- J.-P. REVEILLÈS : The geometry of the intersection of voxels spaces. *In Electronic Notes in Theoretical Computer Science*, vol. 46, p. 285–308, aug 2001.
- C. RIDDELL, P. BRIGGER, R. E. CARSON et S. L. BACHARACH : The watershed algorithm : a method to segment noisy pet transmission images. *IEEE Transactions on Nuclear Science*, 46(3) : 713–719, jun 1999.
- L. ROBERTS : Machine perception of three-dimensional solids. Rap. tech., Massachusetts inst. of tech. Lexington Lincoln lab., may 1963.
- S. ROELS, P. SLAGMOLEN, J. NUYTS, J. A. LEE, D. LOECKX, F. MAES, S. STROOBANTS, F. PENNINGCKX et K. HAUSTERMANS.
- M. ROMBAUT : Fusion de données images segmentées à l'aide du formalisme de dempster-shafer. *In GRETSI*, p. 655–658, Vannes, jan 1999.
- M. ROMBAUT et Y. M. ZHU : Study of Dempster-Shafer theory for image segmentation applications. *Image and Vision Computing*, 20(2) : 15–23, 2002b.
- C. ROMINGER et A. MARTIN : Recalage et fusion d'images sonar multivues : utilisation du conflit. *In Extraction et Gestion des Connaissances*, Hammamet, Tunisie, jan 2010a.
- A. ROQUEL, S. L. HÉGARAT-MASCLE, I. BLOCH et B. VINCKE : A new local measure of disagreement between belief functions - application to localization. *In Belief Functions*, p. 335–342, 2012.
- J. SERRA : *Image Analysis and Mathematical Morphology*. Academic Press, Inc., Orlando, FL, USA, 1983.
- G. SHAFER : *A mathematical theory of evidence*. Princeton university press, 1976.
- G. SHEN, D. NELSON et L. ADLER : Pet tumor segmentation : Comparison of gradient-based algorithm to constant threshold algorithm. *Med. Phys.*, 34(6) : 2395–2395, jun 2007.
- P. SMETS : The combination of evidence in the transferable belief model. *IEEE Trans. Pattern Anal. Mach. Intell.*, 12(5) : 447–458, 1990.

- P. SMETS : Belief functions : The disjunctive rule of combination and the generalized bayesian theorem. *International Journal of Approximate Reasoning*, 9(1) : 1–35, aug 1993.
- P. SMETS : The canonical decomposition of a weighted belief. *In International Joint Conference on Artificial Intelligence*, p. 1896–1901, San Mateo, 1995.
- P. SMETS : Data fusion in the transferable belief model. *In International Conference on Information Fusion*, vol. 1, p. 21–33, Paris, jul 2000.
- I. SOBEL : Neighborhood coding of binary images for fast contour following and general binary array processing. 8(1) : 127–135, août 1978.
- J.-L. STARCK, F. MURTAGH et A. BIJAOU : *Image Processing and Data Analysis : The Multiscale Approach*. Cambridge University Press, 1998.
- R. J. H. M. STEENBAKKERS, J. C. DUPPEN, I. FITTON, K. E. I. DEURLOO, L. J. ZIJP, E. F. I. COMANS, A. L. J. UITTERHOEVE, P. T. R. RODRIGUS, G. W. P. KRAMER, J. BUSSINK, K. DE JAEGER, J. S. A. BELDERBOS, P. J. C. M. NOWAK, M. van HERK et C. R. N. RASCH : Reduction of observer variation using matched ct-pet for lung cancer delineation : a three-dimensional analysis. *Int J Radiat Oncol Biol Phys*, 64(2) : 435–48, 2006.
- D. THORWARTH, S. M. ESCHMANN, F. PAULSEN et M. ALBER : Hypoxia dose painting by numbers : a planning study. *Int. J. Radiat. Oncol. Biol. Phys.*, 68 : 291–300, May 2007.
- D. THORWARTH, S. M. ESCHMANN, J. SCHEIDERBAUER, F. PAULSEN et M. ALBER : Kinetic analysis of dynamic 18F-fluoromisonidazole PET correlates with radiation treatment outcome in head-and-neck cancer. *BMC Cancer*, 5 : 152, 2005.
- S. THUREAU, P. CHAUMET RIFFAUD, P. FERNANDEZ, B. BRIDJI, C. HOUZARD, F. CACHIN, A. STOREZ, I. GARDIN, R. MODZELEWSKI, B. DUBRAY et P. VERA : Reproducibility of uptake intensity scoring and comparison of segmentation methods on 18f-misonidasole (f-miso) and 18fluorothymidine (ft) pet-ct images in patients with non small cell lung cancer. *In International Conference on Molecular Imaging in Radiation Oncology (MIRO)*, p. 36, Vienna, march 2012.
- J. TIAN, X. YANG, L. YU, P. CHEN, J. XIN, L. MA, H. FENG, Y. TAN, Z. ZHAO et W. WU : A multicenter clinical trial on the diagnostic value of dual-tracer PET/CT in pulmonary lesions using 3'-deoxy-3'-18F-fluorothymidine and 18F-FDG. *J. Nucl. Med.*, 49 : 186–194, Feb 2008.



- E. G. TROOST, J. BUSSINK, A. L. HOFFMANN, O. C. BOERMAN, W. J. OYEN et J. H. KAANDERS : 18F-FLT PET/CT for early response monitoring and dose escalation in oropharyngeal tumors. *J. Nucl. Med.*, 51(6) : 866–874, Jun 2010a.
- P. TYLSKI, G. BONNIAUD, J. DECENCIERE, E. and Stawiaski, J. COULOT, D. LEFKOPOULOS et M. RICARD : 18f-fdg pet images segmentation using morphological watershed : a phantom study. vol. 4, p. 2063–2067, San Diego, oct 2006.
- P. VANNOORENBERGHE, O. COLOT et D. de BRUCQ : Color image segmentation using dempster-shafer's theory. *Proc. ICIP'99*, 4 : 300–304, 1999.
- P. VANNOORENBERGHE, E. LEFEVRE et O. COLOT : Traitement d'images et théorie des fonctions de croyance. *In Actes des XII<sup>èmes</sup> Rencontres Francophones sur la Logique Floue et ses Applications*, p. 287–294, Tours, 2003.
- P. VANNOORENBERGHE et P. SMETS : Partially supervised learning by a credal em approach. *In ECSQARU*, p. 956–967, 2005.
- S. VAUCLIN, I. GARDIN, K. DOYEUX, S. HAPDEY, A. EDET-SANSON et P. VERA : Segmentation des images TEP au 18F-FDG : principe et revue de la littérature. *Médecine Nucléaire*, p. 358–69, 2010.
- P. VERA, P. BOHN, A. EDET-SANSON, A. SALLES, S. HAPDEY, I. GARDIN, J. F. MENARD, R. MODZELEWSKI, L. THIBERVILLE et B. DUBRAY : Simultaneous positron emission tomography (PET) assessment of metabolism with <sup>18</sup>F-fluoro-2-deoxy-d-glucose (FDG), proliferation with <sup>18</sup>F-fluoro-thymidine (FLT), and hypoxia with <sup>18</sup>fluoro-misonidazole (F-miso) before and during radiotherapy in patients with non-small-cell lung cancer (NSCLC) : a pilot study. *Radiother Oncol*, 98(1) : 109–116, Jan 2011.
- P. VIOLA et W. M. WELLS, III : Alignment by maximization of mutual information. *Int. J. Comput. Vision*, 24(2) : 137–154, sept. 1997.
- P. H. VIVIER, M. DOLORES, I. GARDIN, P. ZHANG, C. PETITJEAN et J. N. DACHER : In vitro assessment of a 3D segmentation algorithm based on the belief functions theory in calculating renal volumes by MRI. *AJR Am J Roentgenol*, 191 : W127–134, Sep 2008.
- H. WANG et S. MCCLEAN : Deriving evidence theoretical functions in multivariate data spaces : a systematic approach. *IEEE Trans Syst Man Cybern B Cybern*, 38 : 455–465, Apr 2008.
- H. WANG, J. LIU et J. C. AUGUSTO : Mass function derivation and combination in multivariate data spaces. *Inf. Sci.*, 180(6) : 813–819, 2010.

- W. A. WEBER, V. PETERSEN, B. SCHMIDT, L. TYNDALE-HINES, T. LINK, C. PESCHEL et M. SCHWAIGER : Positron emission tomography in non-small-cell lung cancer : prediction of response to chemotherapy by quantitative assessment of glucose use. *J. Clin. Oncol.*, 21 (14) : 2651–2657, Jul 2003.
- J. WOJAK, E. D. ANGELINI et I. BLOCH : Joint variational segmentation of ct-pet data for tumoral lesions. p. 217–220, Rotterdam, Juin 2010a.
- B. XU, Z. GUAN, C. LIU, R. WANG, D. YIN, J. ZHANG, Y. CHEN, S. YAO, M. SHAO, H. WANG et J. TIAN : Can multimodality imaging using 18F-FDG/18F-FLT PET/CT benefit the diagnosis and management of patients with pulmonary lesions? *Eur. J. Nucl. Med. Mol. Imaging*, 38(2) : 285–292, Feb 2011.
- L. XU, A. KRZYZAK et C. SUEN : Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man and Cybernetics*, 22 (3) : 418–435, 1992.
- R. R. YAGER : On the dempster-shafer framework and new combination rules. *Inf. Sci.*, 41 (2) : 93–137, 1987.
- R. R. YAGER : On the dempster-shafer framework and new combination rules. *IEEE Transactions on Systems, Man and Cybernetics - Part A : Systems and Humans*, 31(6) : 1083–4427, 2001.
- S. H. YEH, R. S. LIU, L. C. WU, D. J. YANG, S. H. YEN, C. W. CHANG, T. W. YU, K. L. CHOU et K. Y. CHEN : Fluorine-18 fluoromisonidazole tumour to muscle retention ratio for the detection of hypoxia in nasopharyngeal carcinoma. *Eur J Nucl Med*, 23(10) : 1378–1383, Oct 1996.
- H. YU, C. CALDWELL, K. MAH et D. MOZEG : Coregistered FDG PET/CT-based textural characterization of head and neck cancer for radiation treatment planning. *IEEE Trans Med Imaging*, 28 : 374–383, Mar 2009a.
- H. YU, C. CALDWELL, K. MAH, I. POON, J. BALOGH, R. MACKENZIE, N. KHAOUAM et R. TIRONA : Automated radiation targeting in head-and-neck cancer using region-based texture analysis of PET and CT images. *Int. J. Radiat. Oncol. Biol. Phys.*, 75 : 618–625, Oct 2009b.
- L. A. ZADEH : Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems*, 1(1) : 3–28, 1978.

- L. A. ZADEH : Fuzzy sets. *Information and Control*, 8 : 199–249, 1965.
- L. A. ZADEH : Book review : A mathematical theory of evidence. *AI Magazine*, 5(3) : 81–83, 1984.
- H. ZAIDI, M. DIAZ-GOMEZ, A. BOUDRAA et D. O. SLOSMAN : Fuzzy clustering-based segmented attenuation correction in whole-body PET imaging. *Phys Med Biol*, 47 : 1143–1160, Apr 2002.
- H. ZAIDI et I. EL NAQA : PET-guided delineation of radiation therapy treatment volumes : a survey of image segmentation techniques. *Eur J Nucl Med Mol Imaging*, Mar 2010.
- N. ZHANG, S. RUAN, S. LEBONVALLET, Q. LIAO et Y. ZHU : Kernel feature selection to fuse multi-spectral mri images for brain tumor segmentation. *Comput. Vis. Image Underst.*, 115 (2) : 256–269, fév. 2011.
- P. ZHANG : *Contribution des fonctions de croyance à la segmentation d'images tomographiques thoraciques en radiothérapie conformationnelle*. Thèse de doctorat, Université de Rouen, Rouen, France, nov 2006.
- P. ZHANG, I. GARDIN et P. VANNOORENBERGHE : Information fusion using evidence theory for segmentation of medical images. *In International Colloquium on Information Fusion*, vol. 1, p. 265–272, 2007.
- W. ZHU et T. JIANG : Automation segmentation of PET image for brain tumors. *Nuclear Science Symposium Conference Record*, 4 : 2627–2629, oct 2003.
- H.-J. ZIMMERMANN et P. ZYSNO : Latent connectives in human decision making. *Fuzzy Sets and Systems*, Vol. 4, No. 1. (July 1980), pp. 37-51, doi :10.1016/0165-0114(80)90062-7 Key : citeulike :7801474, 4(1) : 37–51, 1980.
- L. M. ZOUHAL et T. DENGÈUX : An adaptive  $k$ -nn rule based on dempster-shafer theory. *In 6th International Conference on Computer Analysis of Images and Pattern*, p. 310–317, sep 1995.
- L. M. ZOUHAL et T. DENGÈUX : An evidence-theoretic  $k$ -nn rule with parameter optimization. *IEEE Transactions on Systems, Man, and Cybernetics*, 28 : 263–271, 1998.





# Annexes A

## Théorie des fonctions de croyance au travers d'exemples

### Sommaire

---

<b>A.1 Bases théoriques</b> . . . . .	<b>205</b>
A.1.1 Principe des fonctions de croyance à partir d'un exemple . . . . .	205
A.1.2 Définition du cadre de discernement . . . . .	207
A.1.3 Transformations de la fonction de masse . . . . .	207
<b>A.2 Révision des croyances</b> . . . . .	<b>209</b>
A.2.1 Combinaison conjonctive . . . . .	209
A.2.2 Combinaison orthogonale de Dempster . . . . .	210
A.2.3 Conditionnement . . . . .	210
A.2.4 Combinaison disjonctive . . . . .	211
A.2.5 Autres opérateurs de combinaison . . . . .	212

---

Dans cette annexe, les définitions et opérateurs de théorie des fonctions de croyance, telle que présentée au chapitre 4, sont illustrées au travers d'exemples de prévision météorologique.

### A.1 Bases théoriques

#### A.1.1 Principe des fonctions de croyance à partir d'un exemple

Afin d'illustrer le principe des fonctions de croyance et de les comparer à la théorie des probabilités, considérons un exemple de prévisions météorologiques. Soit un ensemble de trois hypothèses simples  $\Omega = \{Soleil, Pluie, Neige\}$ . Un capteur d'humidité, renseignant sur les précipitations, informe que la probabilité  $p^\Omega$  qu'il y ait un ensoleillement est de 0,5. Dans un cadre probabiliste, si la probabilité qu'il y ait un ensoleillement est de 0,5, alors, étant donné le principe de l'équiprobabilité, la probabilité qu'il pleuve et la probabilité qu'il neige sont respectivement de 0,25. Les probabilités  $p^\Omega(\{Soleil\}) = 0,5$ ,  $p^\Omega(\{Pluie\}) = 0,25$  et  $p^\Omega(\{Neige\}) = 0,25$  indiquent avec une forte probabilité qu'un ensoleillement sera présent.

Dans le cadre des fonctions de croyance, la connaissance est modélisée par une distribution  $m^\Omega$  de masses de croyance. L'information fournie par le capteur porte sur l'hypothèse simple  $\{Soleil\}$ , comme pour les probabilités, avec  $m^\Omega(\{Soleil\}) = 0,5$ , mais également sur l'hypothèse multiple  $\{Pluie, Neige\}$  avec  $m^\Omega(\{Pluie, Neige\}) = 0,5$ . En effet, selon le principe des fonctions de croyance, en plus des hypothèses simples :  $\{Soleil\}$ ,  $\{Pluie\}$  et  $\{Neige\}$ , nous pouvons envisager d'affecter des masses aux hypothèses multiples :  $\{Soleil, Pluie\}$ ,  $\{Soleil, Neige\}$ ,  $\{Pluie, Neige\}$  et  $\{Soleil, Pluie, Neige\}$ . Notons que le fait même que le capteur émette une probabilité exprime l'incertitude vis à vis de l'hypothèse qu'il donne. En effet, une probabilité est propre au degré de conformité à la réalité. La théorie des probabilités permet ainsi de modéliser l'incertitude attachée à l'information. Par ailleurs, le capteur est imprécis puisqu'il ne distingue pas le fait qu'il neige du fait qu'il pleuve. L'imprécision sur ces deux hypothèses simples est donc totale. Comme présenté dans le Tableau A.1, la théorie des fonctions de croyance permet de tenir compte de cette imprécision en affectant une masse sur l'union des hypothèses  $\{Pluie\}$  et  $\{Neige\}$ .

$A$	Probabilité $p^\Omega(A)$	Masse de croyance $m^\Omega(A)$
$\{Soleil\}$	0,5	0,5
$\{Pluie\}$	0,25	0
$\{Neige\}$	0,25	0
$\{Soleil, Pluie\}$		0
$\{Soleil, Neige\}$		0
$\{Pluie, Neige\}$		0,5
$\{Soleil, Pluie, Neige\}$		0
$\emptyset$		0

Tableau A.1 – Exemple de modélisation dans le cadre des probabilités avec équiprobabilité et des fonctions de croyance. Les hypothèses multiples ne sont pas prises en compte avec une modélisation effectuée dans le cadre des probabilités.

Contrairement au cadre probabiliste, la modélisation par la théorie des fonctions de croyance a permis de ne pas prendre position par rapport aux hypothèses simples  $\{Pluie\}$  et  $\{Neige\}$  compte tenu de l'absence totale d'information en faveur de l'une ou l'autre de ces hypothèses. Néanmoins, il est intéressant de noter que la théorie des probabilités permet, elle aussi, de mesurer une probabilité sur une union d'hypothèses par la formule :

$$p^\Omega(\{Pluie, Neige\}) = p^\Omega(\{Pluie\}) + p^\Omega(\{Neige\}) - p^\Omega(\{Pluie \cap Neige\}),$$

où  $p^\Omega(\{Pluie \cap Neige\}) = 0$  lorsque les hypothèses simples sont exclusives, ce qui signifie qu'il ne peut pas neiger et pleuvoir le même jour. On peut donc noter que cette contrainte d'additivité

n'est pas présente dans le cadre de la théorie des fonctions de croyance et l'imprécision peut, de cette manière, être prise en compte.

### A.1.2 Définition du cadre de discernement

L'ensemble des hypothèses définies dans un cadre probabiliste par  $\Omega = \{\omega_1, \dots, \omega_k, \dots, \omega_K\}$  (où  $\Omega$  représente l'ensemble des  $K$  hypothèses relatives au problème considéré) est appelé cadre de discernement dans le cadre de la théorie des fonctions de croyance. L'ensemble des hypothèses considérées dans ce cadre est donné par :

$$2^\Omega = \{A | A \subseteq \Omega\} = \{\emptyset, \{\omega_1\}, \dots, \{\omega_K\}, \{\omega_1, \omega_2\}, \dots, \Omega\}.$$

$A$  correspond ainsi à une hypothèse pouvant être simple ou multiple, encore appelée respectivement singleton et disjonction. Notons que  $A$  peut aussi correspondre à l'ensemble vide ( $\emptyset$ ), ce qui permet d'envisager que l'état réel du système observé n'appartienne pas aux hypothèses simples et multiples énoncées. En reprenant l'exemple précédent, le fait qu'il y ait de la grêle n'est, par exemple, pas envisagé dans notre cadre de discernement puisqu'il n'entre pas dans la modélisation. Par contre, nous savons que cet état climatique existe bien dans la réalité. Ainsi, si un expert dit : «il va grêler», nous ne pouvons pas modéliser cette information conformément aux hypothèses définies dans notre cadre de discernement. La masse relative à cette information porte donc sur l'ensemble vide. Dans ce cas de figure, notons qu'il serait plus adéquat d'étendre le cadre de discernement pour qu'il puisse modéliser le fait qu'il puisse grêler. Nous verrons section A.2 que l'analyse de l'ensemble vide à un réel intérêt dans la partie dynamique du niveau *crédal*.

### A.1.3 Transformations de la fonction de masse

Pour illustrer les définitions des fonctions de masse, de crédibilité, et de plausibilité présentées section 4.2, reprenons l'exemple précédent où nous avons des masses non nulles sur les hypothèses  $\{Soleil\}$  et  $\{Pluie, Neige\}$ . Le Tableau A.2 donne les valeurs de  $m^\Omega$ ,  $bel^\Omega$  et  $pl^\Omega$  pour chacune des hypothèses conformément aux définitions 4.2, 4.4 et 4.6.

Nous pouvons observer que la propriété 4.8, pour chaque sous-ensemble, est respectée puisque les crédibilités sont toujours inférieures aux plausibilités. Par ailleurs, en tenant compte par exemple de l'hypothèse  $\{Pluie\}$ , nous observons que les propriétés 4.9 et 4.10 sont respectées car  $bel^\Omega(\{Pluie\}) + bel^\Omega(\overline{\{Pluie\}}) = 0,5$  et  $pl^\Omega(\{Pluie\}) + pl^\Omega(\overline{\{Pluie\}}) = 1,5$ . Enfin, en



considérant l'hypothèse  $\{Soleil\}$ , nous avons la relation  $bel^\Omega(\{Soleil\}) + bel^\Omega(\overline{\{Soleil\}}) = 1$  ainsi que la relation  $bel^\Omega(\{Soleil\}) = pl^\Omega(\{Soleil\})$ , en accord avec la propriété 4.11.

$A$	$m^\Omega(A)$	$bel^\Omega(A)$	$pl^\Omega(A)$
$\{Soleil\}$	0,5	0,5	0,5
$\{Pluie\}$	0	0	0,5
$\{Neige\}$	0	0	0,5
$\{Soleil, Pluie\}$	0	0,5	1
$\{Soleil, Neige\}$	0	0,5	1
$\{Pluie, Neige\}$	0,5	0,5	0,5
$\{Soleil, Pluie, Neige\}$	0	1	1
$\emptyset$	0	0	0

Tableau A.2 – Exemple de modélisation des croyances.  $m^\Omega(A)$ ,  $bel^\Omega(A)$  et  $pl^\Omega(A)$  sont respectivement la masse de croyance, la croyance totale et la croyance potentielle sur  $A$ .

Les fonctions de masse, de crédibilité et de plausibilité sont différentes représentations de la connaissance. Néanmoins, il existe d'autres fonctions dont l'objectif n'est pas de représenter la connaissance. Des outils ont été développés dans le cadre de la théorie des fonctions de croyance qui permettent de fusionner les distributions de masses issues de plusieurs sources d'information. Ces méthodes de fusion, manipulant les distributions de masses, peuvent être calculées de manière simplifiée en utilisant d'autres fonctions telles que la fonction de communalité [Dempster, 1967] ou la fonction d'implicabilité [Smets, 2000].

La fonction de communalité,  $q^\Omega$ , permettant de simplifier l'opérateur de combinaison conjonctive (voir section A.2.1), se détermine à partir d'une fonction de masse par :

$$q^\Omega(A) = \sum_{B \supseteq A} m^\Omega(B), \quad \forall A \subseteq \Omega. \quad (\text{A.1})$$

Elle correspond ainsi à l'ensemble des croyances incluant l'élément considéré.

La fonction d'implicabilité,  $b^\Omega$ , permet de simplifier l'opérateur de combinaison disjonctive (voir section A.2.4), et se détermine comme la fonction de communalité à partir d'une fonction de masse :

$$b^\Omega(A) = \sum_{B \subseteq A} m^\Omega(B), \quad \forall A \subseteq \Omega. \quad (\text{A.2})$$

Elle correspond à la fonction de crédibilité dans le cadre du monde ouvert. Notons qu'elle peut également être déterminée à partir d'une fonction de crédibilité :

$$b^\Omega(A) = bel^\Omega(A) + m^\Omega(\emptyset), \quad \forall A \subseteq \Omega$$

Enfin, notons que l'on peut retrouver une fonction de masse à partir des fonctions de communalité ou d'implicabilité :

$$m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|B|-|A|} q^\Omega(B), \quad \forall A \subseteq \Omega,$$

$$m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|A|-|B|} b^\Omega(B), \quad \forall A \subseteq \Omega.$$

## A.2 Révision des croyances

### A.2.1 Combinaison conjonctive

Soient deux sources d'information : un capteur d'humidité et un expert. Le capteur indique avec une probabilité de 0,4 que le temps est ensoleillé et l'expert dit qu'il pleut avec un indice de confiance de 0,3. Ainsi, cette connaissance permet de répartir les masses relatives aux sources sur les hypothèses à la fois simples et multiples comme présenté dans le Tableau A.3. Nous pouvons remarquer, dans notre exemple, qu'après fusion des sources par la combinaison conjonctive, les masses non nulles sont affectées uniquement aux hypothèses simples ainsi qu'à l'hypothèse  $\emptyset$ . Nous assistons à une réduction de l'imprécision et de l'incertitude induite par la combinaison conjonctive. En effet, la combinaison tend à transférer les masses sur les singletons et les disjonctions dont la cardinalité est faible. Cela tend, de même, à réduire l'intervalle  $[bel^\Omega(A), pl^\Omega(A)]$  témoignant de l'augmentation du degré de confiance. C'est la raison pour laquelle les sources à combiner doivent être fiables. De plus, la masse sur l'ensemble vide s'interprète comme le conflit entre les sources. En effet,  $m_{1 \otimes 2}^\Omega(\emptyset) \neq 0$  signifie que  $S_1$  et  $S_2$  donnent des informations contradictoires.

$A$	$m_1^\Omega(A)$	$m_2^\Omega(A)$	$m_{1 \otimes 2}^\Omega(A)$
$\{Soleil\}$	0,4	0	$0,4 \times 0,7 = 0,28$
$\{Pluie\}$	0	0,3	0,18
$\{Neige\}$	0	0	0,42
$\{Soleil, Pluie\}$	0	0	0
$\{Soleil, Neige\}$	0	0,7	0
$\{Pluie, Neige\}$	0,6	0	0
$\{Soleil, Pluie, Neige\}$	0	0	0
$\emptyset$	0	0	0,12

Tableau A.3 – Illustration de la combinaison conjonctive de deux sources  $S_1$  et  $S_2$ .

Afin de justifier de manière théorique la règle de combinaison conjonctive, Smets [Smets, 1990] présente des justifications axiomatiques dont les primordiales sont les suivantes :

- Axiome 1 :  $m_{1 \otimes 2}^\Omega(A)$  doit seulement être fonction de  $m_1^\Omega$ ,  $m_2^\Omega$  et  $A$ .

- Axiome 2 :  $\odot$  doit être commutative :  $m_{1\odot 2}^\Omega(A) = m_{2\odot 1}^\Omega(A)$ .
- Axiome 3 :  $\odot$  doit être associative :  $m_{(1\odot 2)\odot 3}^\Omega(A) = m_{1\odot (2\odot 3)}^\Omega(A)$ .

### A.2.2 Combinaison orthogonale de Dempster

Soit à présent un capteur donnant une probabilité d'ensoleillement de 0,1, ainsi qu'une probabilité sur le fait qu'il pleuve de 0,9. Un second capteur donne lui aussi une probabilité d'ensoleillement de 0,1, mais une probabilité qu'il neige de 0,9. D'après la règle de combinaison de Dempster (définition 4.14) normalisant la combinaison par le conflit, la croyance d'avoir un temps ensoleillé vaut 1 et les croyances d'avoir de la pluie ou de la neige valent 0. On voit dans le Tableau A.4 que les règles de combinaison conjonctives et orthogonales donnent des résultats très différents. La règle de combinaison conjonctive nous informe que les sources sont toutes les deux en faveur de  $\{Soleil\}$  mais faiblement et qu'il y a un très fort conflit entre les sources. La combinaison orthogonale nous donne une certitude sur l'hypothèse  $\{Soleil\}$ . On comprend aisément sur cet exemple que la règle de combinaison conjonctive permet une modélisation plus sûre et plus riche de l'information.

$A$	$m_1^\Omega(A)$	$m_2^\Omega(A)$	$m_{1\odot 2}^\Omega(A)$	$m_{1\oplus 2}^\Omega(A)$
$\{Soleil\}$	0,1	0,1	0,01	$\frac{0,01}{1-\kappa} = 1$
$\{Pluie\}$	0,9	0	0	0
$\{Neige\}$	0	0,9	0	0
$\emptyset$	0	0	$\kappa = 0,99$	0

Tableau A.4 – Exemple illustrant l'intérêt d'utiliser l'opération de combinaison en monde ouvert plutôt qu'en monde fermé.

### A.2.3 Conditionnement

Soient des masses réparties sur trois hypothèses :  $m^\Omega(\{Soleil\}) = 0,4$ ,  $m^\Omega(\{Neige\}) = 0,1$  et  $m^\Omega(\{Pluie, Neige\}) = 0,5$ . Soit une nouvelle information issue d'un thermomètre indiquant une température supérieure à  $20^\circ C$ . Cette certitude sur la non-présence de neige signifie que  $\{Soleil, Pluie\}$ , bien qu'imprécis, est vrai. Ainsi, en appliquant la règle de conditionnement, les masses sur  $\{Pluie, Neige\}$  et sur  $\{Neige\}$ , dans le cadre du monde ouvert, se voient transférées respectivement sur  $\{Pluie\}$  et sur l'ensemble vide. Dans le cadre du monde fermé, la masse sur l'ensemble vide doit rester nulle et les masses des autres hypothèses sont normalisées de sorte que  $\sum_{A \in \Omega} m^\Omega(A) = 1$  soit respecté. Le coefficient de normalisation correspondant est donné par :  $\kappa_C = \frac{1}{1-0,1} = 1,11$ . Le Tableau A.5 présente les masses relatives aux différentes hypothèses après conditionnement dans le cadre des mondes ouvert et fermé.

$A$	$m^\Omega(A)$	Certitude sur $\{Soleil, Pluie\}$	$m^\Omega(A \{Soleil, Pluie\})$	
			monde ouvert	monde fermé
$\{Soleil\}$	0,4	0	0,4	0,44
$\{Pluie\}$	0	0	0,5	0,56
$\{Neige\}$	0,1	0	0	0
$\{Soleil, Pluie\}$	0	1	0	0
$\{Soleil, Neige\}$	0	0	0	0
$\{Pluie, Neige\}$	0,5	0	0	0
$\{Soleil, Pluie, Neige\}$	0	0	0	0
$\emptyset$	0	0	0,1	0

Tableau A.5 – Illustration du conditionnement.

### A.2.4 Combinaison disjonctive

Soit un capteur donnant un ensoleillement avec un indice de 0,1 ainsi qu'un indice de 0,9 sur le fait qu'il pleuve. Un second capteur donne lui aussi un indice d'ensoleillement de 0,1 mais un indice sur le fait qu'il neige de 0,9. Ces deux capteurs, sont deux sources d'information donnant tous deux une relativement forte certitude sur deux hypothèses contradictoires. Dans un tel cas de figure, il semble difficile de considérer que les deux capteurs sont fiables. En utilisant la combinaison disjonctive, on considère que seul l'un des capteurs est fiable, mais sans nécessairement savoir lequel. Les résultats des combinaisons conjonctive et disjonctive sont donnés au Tableau A.6. Contrairement à la combinaison conjonctive où la masse sur le conflit est très importante, la combinaison disjonctive admet que certaines sources puissent ne pas être fiables, d'où la répartition des masses sur les hypothèses multiples. Seulement, il faut noter que cette répartition des masses sur les hypothèses multiples, si elle paraît avantageuse ici, peut être désavantageuse dans d'autres cas de figure. En effet, les masses sont transférées sur les plus grands sous-ensembles, augmentant l'incertitude et l'imprécision.

$A$	$m_1^\Omega(A)$	$m_2^\Omega(A)$	$m_{1\oplus 2}^\Omega(A)$	$m_{1\otimes 2}^\Omega(A)$
$\{Soleil\}$	0,1	0,1	0,01	0,01
$\{Pluie\}$	0,9	0	0	0
$\{Neige\}$	0	0,9	0	0
$\{Soleil, Pluie\}$	0	0	0	0,09
$\{Soleil, Neige\}$	0	0	0	0,09
$\{Pluie, Neige\}$	0	0	0	0,81
$\{Soleil, Pluie, Neige\}$	0	0	0	0
$\emptyset$	0	0	0,99	0

Tableau A.6 – Exemple illustrant l'intérêt d'utiliser l'opération de combinaison disjonctive plutôt que conjonctive.

### A.2.5 Autres opérateurs de combinaison

Lorsque deux distributions de masses identiques donnent après combinaison une distribution de masses différente, la combinaison est non-idempotente. Les combinaisons conjonctive, orthogonale et disjonctive présentées jusqu'ici possèdent cette propriété, comme illustré Tableau A.7 où deux sources composées d'hypothèses simples non nulles sont fusionnées par les opérateurs conjonctifs en mondes ouvert et fermé, ainsi que par l'opérateur disjonctif. Notons qu'à partir de cet exemple, avec la combinaison conjonctive en monde fermé, deux masses fortes, bien qu'elles soient égales donnent, après fusion, une masse qui leur est supérieure. *A contrario*, deux masses faibles égales donnent après fusion une masse qui leur est plus faible. Par ce biais, on observe une réduction des incertitudes. Néanmoins, pour les raisons exposées section A.2.2, il est d'un certain point de vue plus intéressant d'utiliser la combinaison en monde ouvert, donnant une information sur le conflit présent entre les sources. Notons, dans le cadre d'une application préférant s'affranchir de l'ensemble vide, c'est à dire dans le cadre d'une application en monde fermé, que l'approche de Yager [Yager, 1987] peut être utilisée. Il propose de transférer la masse de conflit à l'ensemble  $\Omega$ , transformant ainsi le conflit en ignorance. Dans [Dubois et Prade, 1988], les auteurs proposent une méthode de combinaison qui, à l'issue de la combinaison conjonctive en monde ouvert, vise à rediriger le conflit généré entre deux hypothèses qui ne s'intersectent pas vers l'union de ces deux hypothèses. Cette combinaison est donnée par :

$$m_{1\oplus 2}^{\Omega}(A) = m_{1\otimes 2}^{\Omega}(A) + \sum_{B \cap C = \emptyset, B \cup C = A} m_1^{\Omega}(B)m_2^{\Omega}(C) \quad \forall A \subseteq \Omega,$$

où  $B$  et  $C$  sont deux partitions de  $A$ . En outre, nous pouvons observer Tableau A.7 que la combinaison disjonctive est elle aussi intéressante car elle permet un transfert des hypothèses conflictuelles sur les hypothèses de plus haute cardinalité.

$A$	$m_1^{\Omega}(A)$	$m_2^{\Omega}(A)$	$m_{1\otimes 2}^{\Omega}(A)$	$m_{1\oplus 2}^{\Omega}(A)$	$m_{1\ominus 2}^{\Omega}(A)$
{Soleil}	0,6	0,6	0,36	0,78	$0,6 \times 0,6 = 0,36$
{Pluie}	0,3	0,3	0,09	0,2	0,09
{Neige}	0,1	0,1	0,01	0,02	0,01
{Soleil, Pluie}	0	0	0	0	$2(0,6 \times 0,3) = 0,36$
{Soleil, Neige}	0	0	0	0	0,12
{Pluie, Neige}	0	0	0	0	0,06
{Soleil, Pluie, Neige}	0	0	0	0	0
$\emptyset$	0	0	0,54	0	0

Tableau A.7 – Exemple illustrant les combinaisons conjonctives, non normalisée et normalisée, et la combinaison disjonctive de deux sources  $S_1$  et  $S_2$  ayant les mêmes masses de croyance.

