



HAL
open science

Segmentation d'images cérébrales : État de l'art

Jérémy Lecoer, Christian Barillot

► **To cite this version:**

Jérémy Lecoer, Christian Barillot. Segmentation d'images cérébrales : État de l'art. [Rapport de recherche] RR-6306, INRIA. 2007, pp.46. inria-00175188v3

HAL Id: inria-00175188

<https://inria.hal.science/inria-00175188v3>

Submitted on 18 Feb 2008

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.



INSTITUT NATIONAL DE RECHERCHE EN INFORMATIQUE ET EN AUTOMATIQUE

Segmentation d'images cérébrales : État de l'art

Jérémy Lecoer — Christian Barillot

N° 6306 — version 3

version initiale Juillet 2007 — version révisée Février 2008

Thème BIO



*R*apport
de recherche

Segmentation d'images cérébrales : État de l'art

Jérémy Lecoœur* , Christian Barillot†

Thème BIO — Systèmes biologiques
Projet VisAGeS

Rapport de recherche n° 6306 — version 3 — version initiale Juillet 2007 — version révisée
Février 2008 — 45 pages

Résumé : La segmentation d'images est au coeur de nombreux problèmes en imagerie médicale puisque bien souvent elle constitue la première étape d'un véritable flux de traitements d'image. Selon la suite à donner à ces images, certaines méthodes se révèlent plus probantes et le choix à effectuer n'est pas chose aisée. Nous nous proposons ici de dresser un état de l'art des différentes méthodes existantes pour la segmentation d'images cérébrales. Après un bref rappel de la définition d'une segmentation, nous exposons les différentes techniques existantes, classées selon leurs approches. Nous en avons retenu cinq que sont les approches basées contours, celles s'appuyant sur la notion de région, les approches structurelles, celles basées sur la forme et enfin celles utilisant des notions de graphes. Pour chacune de ces approches, nous avons ensuite expliqué et illustré leurs méthodes les plus remarquables. Cette revue ne se veut pas exhaustive et le classement de certaines méthodes pourraient être discuté puisqu'à la frontière entre plusieurs approches.

Mots-clés : segmentation, imagerie numérique, IRM, cerveau

* IRISA-INRIA, jlecoeur@irisa.fr

† IRISA-CNRS, cbarillot@irisa.fr

Brain Images Segmentation : A State Of The Art

Abstract: Image segmentation affects many problems in medical imaging as it is often a first step in a workflow of image processing. Depending on the use of these images, some methods are better but the choice is not easy. We propose here to make a state of the art of the different existing methods in brain images segmentation. After a brief definition of segmentation, we expose the different ways, under a classification by their approach. We decided to split the methods in five categories which are contour-based, region-based, structure-based, shape-based and endly graph-based approaches. For each approach, we have explained and shown the most consistent methods. This review is not meant to be exhaustive and the classification of some methods could be discussed as they are on the border of several approaches.

Key-words: segmentation, image processing, MRI, brain

Table des matières

Table des matières	3
1 Introduction	5
2 Qu'est-ce que la segmentation ?	5
3 Les différentes approches	6
3.1 Contour	8
3.1.1 Espace-échelle	8
3.1.2 Modèles dérivatifs	9
3.2 Région	12
3.2.1 Classification Déterministe Supervisée	12
Réseaux de neurones	12
3.2.2 Classification Déterministe Non Supervisée	13
K-Moyennes	13
C-moyennes floues et c-moyennes floues adaptatives	14
Mean Shift	14
3.2.3 Classification Probabiliste Paramétrique	16
Mélange de Lois	16
3.2.4 Classification Probabiliste Non-Paramétrique	17
Champs Aléatoires de Markov	17
Machine à Vecteurs de Support	18
3.3 Approches Structurelles	19
3.3.1 Gradient Morphologique	19
3.3.2 Ligne de Partage des Eaux	20
3.4 Forme	21
3.4.1 Recalage d'atlas	21
3.4.2 Transformation dans un sous-espace	22
Ondelettes	22
Harmoniques Sphériques	24
Modèle actif de Forme	25
Modèle Actif d'Apparence	25
3.4.3 Forme paramétrique	26
Contours Actifs	27
3.4.4 Forme discrète	27
Level Set Géométrique	28
Level Set Géodésique	29
3.5 Théorie des Graphes	30
3.5.1 Hypergraphes	30
3.5.2 Graph Cuts	31
4 Conclusion	34

1 Introduction

Dans ce rapport, nous allons nous efforcer d'esquisser un état de l'art de la segmentation d'images. Cette revue des différentes techniques et approches n'a pas pour but d'être exhaustive mais de montrer la grande diversité qui existe au sein de ce vaste domaine. Les références sont légions et celles citées en exemples sont celles qui nous ont semblées les plus à même d'illustrer nos propos.

Dans un premier temps, nous réfléchissons sur les tenants et aboutissants de la segmentation et les critères de véracité d'une segmentation, puis, dans un second temps, nous nous intéresserons aux différentes méthodes que nous avons classées en cinq grands thèmes que sont les approches opérant sur les contours, celles basées sur la forme, celles reposant sur un paradigme de régions, celles utilisant une approche structurelle et enfin celles faisant appel à la théorie des graphes.

2 Qu'est-ce que la segmentation ?

Il n'est pas aisé de trouver une seule définition de la segmentation car cette tâche est souvent confondue avec la classification ou l'étiquetage, on peut néanmoins essayer d'en trouver une afin de fixer le cadre dans lequel nous écrirons et ainsi faire disparaître les ambiguïtés.

Segmenter une image signifie trouver ses régions homogènes et ses contours. Ces régions et contours sont supposées être pertinents, c'est-à-dire que les régions doivent correspondre aux parties significatives des objets du monde réel, et les contours à leurs contours apparents.

Une définition formelle d'un algorithme de segmentation a été donné par Horowitz et Pavlidis [74, 75] en 1975.

Définition 1 Soit X le domaine de l'image et f la fonction qui associe à chaque pixel une valeur $f(x,y)$. Si nous définissons un prédicat P sur l'ensemble des parties de X , la segmentation de X est définie comme une partition de X en n sous-ensemble $\{R_1, \dots, R_n\}$ tels que :

1. $X = \bigsqcup_{i=1}^n R_i$
2. $\forall i \in \{1, \dots, n\}$ R_i est connexe
3. $\forall i \in \{1, \dots, n\}$ $P(R_i) = \text{vrai}$
4. $\forall i, j \in \{1, \dots, n\}^2$ R_i est adjacent à R_j et $i \neq j \Rightarrow P(R_i \cup R_j) = \text{faux}$

où \sqcup représente une union d'ensemble disjoints.

Le prédicat P est utilisé pour tester l'homogénéité des ensembles R_i . Ces sous-ensembles constituent les régions de l'image. Une segmentation de l'image est donc sa décomposition en un ensemble de régions homogènes, le critère d'homogénéité P restant à déterminer.

Zucker [186] a résumé les conditions de la définition d'Horowitz comme suit : la première condition implique que tout pixel de l'image appartienne à une région et une seule. Cela signifie que l'algorithme de segmentation ne doit pas se terminer avant d'avoir traité tous les points. La seconde condition implique que toute région doit être connexe. La connexité des régions étant induite par le voisinage défini sur l'image. La troisième condition implique que chaque région doit être homogène. Enfin, la quatrième condition est une condition de maximalité indiquant que la fusion de deux régions ne doit pas être homogène. Il est important de remarquer que le nombre n de régions formant la partition de l'image reste indéterminé. Il peut donc exister plusieurs segmentations possibles pour un prédicat P donné.

Les psychophysiciens et les gestaltistes sont d'accord sur le fait qu'un processus de segmentation se produit aux toutes premières étapes du processus de perception visuelle [106, 90, 94]. De plus, ils

ont prouvé que ces premières étapes sont tout à fait indépendantes d'un quelconque apprentissage ou d'une connaissance à priori sur le monde (le domaine de l'image). Cela signifie qu'un algorithme programmé, traitant des images numériques, est capable de faire la même chose.




FIG. 1 – Schéma d'un système imageur

L'image d'origine (notée f) est relié à l'image observée (notée p) par une transformation qui fait intervenir deux types de phénomènes. Les premiers sont déterministes (ex : projection, défauts du système imageur, etc.) et les seconds sont aléatoires, connus uniquement en termes de statistiques (ex : bruit de mesure).

Le terme "problème inverse" désigne les problèmes consistant à inverser cette transformation : retrouver l'image f à partir de p , ce qui n'est pas toujours possible en pratique. En effet, la plupart des problèmes inverses en traitement d'image sont par nature mal posés. Au sens d'Hadamard [68], un problème est mal posé si une des conditions suivantes n'est pas respectée :

- il existe une solution au problème,
- cette solution est unique,
- cette solution dépend continûment des données.

La seule connaissance des données observées est insuffisante pour assurer l'existence, l'unicité et la stabilité d'une solution. En général, on introduit un *a priori* sur la solution, que l'on appelle régularisation. La segmentation consiste donc à trouver une approximation de f suffisamment correcte pour effectuer les phases de travail en aval.

3 Les différentes approches

La segmentation est un vaste sujet d'étude et fait partie des grands thèmes de l'imagerie numérique. A ce titre, de nombreuses publications font état de segmentations. Comment préférer l'une ou l'autre est un débat ouvert qui fait rage dans bien des laboratoires. En effet, pour valider correctement une segmentation d'objets naturels, comme en imagerie médicale, il faut disposer de la vérité terrain; ce qui est bien difficile dans le cas de la segmentation, car comment définir de façon précise où commencent et où s'arrêtent les objets sur une image? Il n'y a donc pas une mais des segmentations possibles sur une même image et elles sont bien souvent subjectives. De même, selon ce que nous voulons segmenter, certaines techniques seront plus à même d'y parvenir.

Nous allons donc présenter dans cette section diverses techniques connues de segmentation en les organisant selon l'approche qui les régit. Ainsi, nous avons retenu cinq approches, mais nous verrons au travers d'exemples que ces catégories ne sont pas rigides et que certaines méthodes se situent à la frontière de nos cinq grands thèmes que sont les segmentations utilisant les contours comme critère de décision, celles basées sur les régions, celles basées sur la forme, celles préférant une approche structurale et enfin celles faisant appel à la théorie des graphes. Cette classification et ses ramifications plus poussées sont représentées sur la figure 2.




FIG. 2 – Classification des différentes méthodes évoquées dans ce rapport.

3.1 Contour

Dans l'approche "contour" (ou "frontière"), on considère que les primitives à extraire sont les lignes de contrastes séparant des régions de niveaux de gris différents et relativement homogènes, ou bien des régions de texture différentes. En pratique, il s'agit de reconnaître les zones de transition et de localiser au mieux la frontière entre les régions.

On distingue notamment les modèles dérivatifs et les modèles d'espace-échelle.

3.1.1 Espace-échelle

La notion d'espace-échelle (en anglais *scale-space*) est générale et s'applique dans des dimensions arbitraires. C'est une théorie formelle pour manipuler des structures d'image à différentes échelles de telle manière que les structures puissent être successivement supprimées et un paramètre t d'échelle puisse être associé à chaque niveau dans la représentation du scale-space. Pour simplifier, nous ne décrirons ici que le cas des images en 2 dimensions.

Pour une image donnée $f(x, y)$, sa représentation linéaire en scale-space est une famille de signaux dérivés $L(x, y, t)$ défini par la convolution de $f(x, y)$ avec le noyau Gaussien :

$$g(x, y, t) = \frac{1}{2\pi t} e^{-(x^2+y^2)/2t}.$$

telle que :

$$L(x, y, t) = g(x, y, t) * f(x, y).$$

où $t = \sigma^2$ est la variance de la gaussienne. De façon équivalente, la famille scale-space peut être générée à partir des solutions de l'équation de la chaleur :

$$\partial_t L = \frac{1}{2} \nabla^2 L,$$

avec la condition initiale $L(x, y, 0) = f(x, y)$

Les travaux de Witkin sur le scale-space [173, 174] introduisent la notion qu'un signal en une dimension peut être segmenté sans ambiguïté en régions, avec un paramètre d'échelle. Une observation clef est que le passage par zéro des dérivées secondes des versions lissées multi-échelle d'un signal forment un arbre d'imbrication qui définit les relations hiérarchiques entre les segments à différentes échelles. La structure d'imbrication de Witkin est cependant spécifique aux signaux en une dimension ; néanmoins, cette idée générale a inspiré plusieurs auteurs pour trouver des schémas de raffinement successif pour la segmentation d'image. En lien avec ces travaux fondateurs, on trouve les théories de Marr, basées notamment sur la vision stéréoscopique humaine [116, 117, 118, 119], qui expliquent la rémanence de structures spatiales à différentes échelles et son utilité dans les méthodes informatiques de segmentation.

Koenderink a établi dans [92] que l'équation génératrice d'un scale-space linéaire en deux dimensions est l'équation de diffusion suivante :

$$\frac{\partial L}{\partial s} = \vec{\nabla} \cdot \vec{\nabla} L = \delta L = L_{xx} * L_{yy}.$$

Quand cette diffusion est égale dans toutes les directions, on parle de diffusion *isotropique*, si elle est égale en tout point de l'image, elle est dite *homogène*. À cause de l'équation de diffusion, le procédé de génération d'une représentation multi-échelle est aussi connu sous le nom d'*évolution de l'image*. La dérivation de cette équation a été faite de plusieurs façons [2], parmi lesquelles :

- La causalité [92] : ce qui est à une échelle donnée ne peut qu'être "causé" par les échelles inférieures.
- Le principe du maximum [79] : pour tout changement d'échelle, la luminance maximale à l'échelle supérieure est toujours plus petite que l'intensité maximale à l'échelle plus fine.
- Pas de nouvel extremum dans les échelles plus larges [2, 108] : cela n'est valable que pour les signaux 1D.
- Physique de la diffusion de la luminance : la décroissance de la luminance dans le temps [93] (ou les échelles [92], ce qui est ici équivalent) est égale à la divergence d'un flux, *i.e.*, égale à la divergence du gradient de luminance.




FIG. 3 – Exemple de scale space gaussien

Lindeberg [109] a cherché à lier les extrema locaux et les points selles à travers les échelles et a proposé une représentation d'image appelée *scale-space primal sketch* qui explicite les relations entre structures à différentes échelles et quelles caractéristiques de l'image sont stables le long d'un grand intervalle d'échelle. Bergholm [8] a proposé de détecter les contours dans les échelles brutes du scale-space et de les retrouver par *track-back* aux échelles fines. On retrouve le principe d'approche hiérarchique multi-résolution, cette fois basé sur les extrema d'intensité, dans les travaux de Lifshitz [107] qui applique le scale-space sur un espace discret.

Lachmann [96] a exploré différentes techniques scale-space appliquées à l'imagerie médicale 3D. Une revue des différentes techniques de segmentation en scale-space a été faite par Henkel en 1995 dans [73].

Plus récemment, ces idées de segmentation multi-échelle liant les structures d'images au travers des différents échelles a été repris par Florack and Kuijper dans [59]. Rahman et coll. proposent dans [140] d'exploiter le gradient à différentes échelles pour segmenter les images.

3.1.2 Modèles dérivatifs

Les modèles dérivatifs consistent à modéliser les contours ou des zones d'images et supposent que l'image numérique provient de l'échantillonnage d'une fonction scalaire à support borné et dérivable en tout point. Ces variations d'intensité de l'image peuvent correspondre à des variations d'illuminaitions (ombres), des changements d'orientation ou de distance à l'observateur, des changements de réflectance de surface, des variations d'absorption des rayons, etc. Or, dans le traitement d'une image numérique, toutes ces grandeurs sont condensées en une seule variable bi ou tridimensionnelle ; dans le cas monochrome, c'est l'intensité lumineuse.

On distingue trois types de contours simples :

- Marche d'escalier : le contour est net (contour idéal).
- Rampe : le contour est plus flou.
- Toit : il s'agit d'une ligne sur un fond uniforme.




FIG. 4 – Modèles de contours

Ce sont des contours idéaux - cf. figure 4 - qui ont permis une approche de détection par les opérateur gradient et laplacien. Les variations locales d'intensité constituent la source de ces opérateurs; ainsi, le gradient est une fonction vectorielle des pixels $[i, j]$:

$$\nabla f[i, j] = \left(\frac{\partial f}{\partial x}[i, j], \frac{\partial f}{\partial y}[i, j] \right)$$

alors que le laplacien est une fonction scalaire de $[i, j]$:

$$\Delta f[i, j] = \left(\frac{\partial^2 f}{\partial x^2}[i, j] + \frac{\partial^2 f}{\partial y^2}[i, j] \right)$$

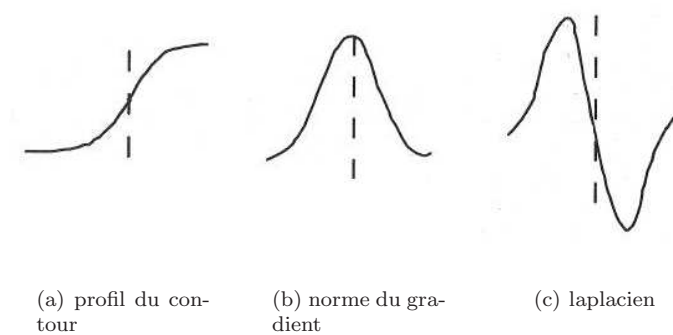


FIG. 5 – Opérateurs dérivatifs

Comme on le voit sur la figure 5, on peut trouver le point de contour par détermination du maximum de la norme du gradient ou bien en étudiant le passage par zéro du laplacien. Ainsi, les opérateurs de Roberts, Prewitt et Sobel [159] donnent une estimation de la dérivée directionnelle de l'image par rapport à un axe. Ces opérateurs sont très sensibles aux bruits mais ils ont le mérite d'avoir posé les bases de la détection de contours.

Les opérateurs Laplacien ne sont pas directionnels. En effet, si par hypothèse de départ, la fonction image est supposée continue, alors les propriétés de la dérivée seconde d'une fonction sont utilisées pour caractériser un contour par la présence d'un extremum local par le passage à zéro de la dérivée seconde. Ainsi en utilisant également les propriétés de différentiation l'opérateur Laplacien peut s'écrire sous la forme suivante :

$$\Delta f(x, y) = f(x + 1, y) + f(x - 1, y) + f(x, y + 1) + f(x, y - 1) - 4f(x, y)$$

Généralement écrit par le masque de convolution suivant :

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

Nous remarquons que l'opérateur Laplacien est symétrique quelque soit l'orientation choisie, il n'est donc pas directionnel. L'opérateur Laplacien est lui aussi fortement sensible aux bruits. On peut aussi approximer le Laplacien par différence de deux lissages, l'un étant un lissage fort, l'autre un lissage faible. En employant un filtre gaussien, on a alors l'opérateur DOG (Difference Of Gaussians) de Marr et Hildreth [117].

Canny [22, 23] est l'instigateur d'une technique d'optimisation, il démontre qu'on ne peut pas obtenir à la fois une bonne détection et une bonne localisation du contour. Pour palier à cela, Canny ajoute un critère supplémentaire pour définir un détecteur optimal : la non-multiplicité des maxima locaux. Il développe un filtre à réponse impulsionnelle finie. L'approche de Deriche [52, 51] a été de développer un filtre optimal à réponse impulsionnelle infinie. Les différentes littératures présentent la technique de Deriche comme étant une référence dans les détections de contours. Deriche met en oeuvre un opérateur particulier où les maxima du gradient sont recherchés dans la direction du gradient par l'opérateur suivant :

$$h(x) = \frac{c}{\omega} e^{-\alpha|x|} \sin \omega x \quad \text{avec } \alpha, \omega, c \in \mathbb{R}$$

Les performances de ce filtre sont maximales quand ω est proche de 0. Selon la valeur de α , la qualité de segmentation diffère : quand α est petit, il y a peu de contours, une bonne qualité de détection mais les contours sont délocalisés; quand α est grand, la localisation est meilleur, le nombre de contours est plus grand mais la qualité de détection est moins bonne.

Shen et Castan [156] ont proposé un opérateur optimisant un critère incluant la détection et la localisation. Les critères qu'ils obtiennent correspondent aux critères de détection et de localisation de Canny et les filtres obtenus sont assez similaires dans la pratique. Le calcul du filtre de lissage optimal se fait par modélisation de la frontière par un échelon noyé dans un bruit blanc stationnaire additif de moyenne nulle. Le filtre de lissage obtenu par Shen et Castan s'écrit :

$$f(x) = ce^{-\alpha|x|}$$

$$c = \frac{1 - e^{-\alpha}}{1 + e^{-\alpha}} \quad (\text{pour avoir un filtre normalisé})$$

et le filtre de dérivation correspondant :

$$h(x) = \begin{cases} d.e^{-\alpha x} & \text{si } x > 0 \\ d.e^{\alpha x} & \text{si } x \leq 0 \end{cases}$$

avec $d = 1 - e^{-\alpha}$. Le paramètre α définit la "largeur" du filtre : plus α est petit, plus le lissage effectué par le filtre est important. Remarquons que la discontinuité d'ordre 1 au point 0 du filtre de Shen permet d'éviter une délocalisation importante des contours dans l'image lissée, même avec des valeurs faibles de α . Cependant, cette discontinuité peut entraîner la détection de contours multiples.

Monga et coll. ont utilisé le paradigme des dérivées partielles dans le cadre de la segmentation d'images biomédicales dans [128], notamment appliqué aux IRM et aux scanners cardiaques. Ils ont adapté les filtres de Deriche et de Shen à des images en 3 dimensions via une implémentation récursive [127] et ont fait le lien entre ces techniques de détection de contours et la modélisation de surface [124, 125, 126]. Ces techniques ont cependant des potentiels limités et ne sont plus guère utilisées de nos jours.

3.2 Région

L'approche "région" de la segmentation utilise des techniques d'identification et de localisation d'ensembles connexes de pixels. Les méthodes par classification ont pour but de partitionner les images en plusieurs classes - comme leur nom l'indique - et constituent le plus souvent une étape dans la segmentation d'objet à proprement parler. Cependant, leur utilisation dans les méthodes de segmentation étant très répandue, il nous a paru judicieux d'en expliquer les ressorts.

Ces différentes classifications peuvent être séparées selon plusieurs critères : probabilistes ou déterministes, paramétriques ou non, supervisées ou non. Nous présenterons donc un panel de ces méthodes parmi lesquelles nous trouverons les réseaux de neurones (méthode déterministe supervisée), les approches K-Moyennes, Fuzzy C-Means, Adaptive Fuzzy C-Means et Mean Shift (déterministes non supervisées), les différentes mixtures de lois (probabilistes paramétriques) et les approches markoviennes et par Machine à Vecteurs de Support (probabilistes non-paramétriques).

3.2.1 Classification Déterministe Supervisée

Réseaux de neurones

Un réseau de neurones artificiels [158, 72] est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Chaque couche i est composée de N_i neurones - cf. figure 6 - prenant leurs entrées sur les N_{i-1} neurones de la couche précédente. À chaque synapse est associée un poids synaptique, de sorte que les N_{i-1} sont multipliés par ce poids, puis additionnés par les neurones de niveau i , ce qui est équivalent à multiplier le vecteur d'entrée par une matrice de transformation. Mettre l'une derrière l'autre les différentes couches d'un réseau de neurones reviendrait à mettre en cascade plusieurs matrices de transformation et pourrait se ramener à une seule matrice, produit des autres, s'il n'y avait à chaque couche, la fonction de sortie qui introduit une non-linéarité à chaque étape. Ceci montre l'importance du choix judicieux d'une bonne fonction de sortie : un réseau de neurones dont les sorties seraient linéaires, n'aurait aucun intérêt.

Au delà de cette structure simple, le réseau de neurones peut également contenir des boucles qui en changent radicalement les possibilités mais aussi la complexité. De la même façon que des




FIG. 6 – Structure d'un neurone artificiel. Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie.

boucles peuvent transformer une logique combinatoire en logique séquentielle, les boucles dans un réseau de neurones transforment un simple dispositif de reconnaissance d'entrées, en une machine complexe capable de toute sortes de comportements.

Classiquement, en segmentation d'images médicales, les réseaux de neurones sont utilisés comme classifieurs. Les poids synaptiques sont déterminés par apprentissage sur une base d'image dont le résultat de segmentation est connu, on parle alors de réseau de neurones *supervisé*. Souvent, les neurones d'entrées sont les différentes IRM disponibles et les neurones de sorties nous donnent alors les différentes classes recherchées [78, 151]. Il est en outre possible d'introduire des informations *a priori* en plus des volumes et donc de donner plus de robustesse à cette classification.

Mais l'inconvénient majeur de cette méthode par réseaux de neurones est l'étape d'apprentissage qui demandent une intervention manuelle pour donner cette vérité terrain dont le réseau a besoin pour calculer les poids synaptiques.

3.2.2 Classification Déterministe Non Supervisée

K-Moyennes

L'algorithme des k -moyennes [112] classe les objets selon leurs attributs en k parties (ou *clusters*) en supposant que les attributs des objets forment un espace vectoriel. L'objectif est de minimiser la variance intra-cluster :

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} |x_j - \mu_i|^2$$

où $S_i, i = 1, 2, \dots, k$ sont les k clusters et μ_i est le centroïde ou point moyen des points $x_j \in S_i$.

L'algorithme commence par partitionner les points en k ensembles initiaux, soit au hasard, soit en utilisant une heuristique. Il calcule ensuite le centroïde de chaque ensemble et construit une nouvelle partition en associant chaque point avec le centroïde le plus proche. S'ensuit une alternance entre calcul des centroïdes des nouveaux clusters et appariement des points avec le centroïde le plus proche jusqu'à convergence. Celle-ci est obtenue quand plus aucun point ne change de groupe (ou bien quand les centroïdes ne changent plus).

Cet algorithme est très populaire car extrêmement rapide en pratique. En effet, le nombre d'itérations est typiquement inférieur au nombre de points. En terme de performance, cet algorithme ne garantit pas un optimum global. La qualité de la solution dépend grandement des ensembles initiaux et peut, en pratique, être bien en deça de l'optimum global. Comme l'algorithme est très rapide, une méthode courante est de le lancer plusieurs fois et de retourner la meilleur partition. L'autre problème est qu'il est nécessaire de donner le nombre de clusters (*i.e.* k) à trouver ; cela n'étant pas réellement handicapant dans le cas de la segmentation cérébrale puisque le nombre de classes est, le plus souvent, connu.

Cet algorithme a été utilisé pour segmenter le cerveau [170, 181] avec des résultats plutôt satisfaisants mais la qualité non constante de la solution en fait un algorithme à proscrire pour une automatisation du travail.

C-moyennes floues et c-moyennes floues adaptatives

L'algorithme des c -moyennes floues (ou *fuzzy c-means* - FCM - en anglais) introduit par Dunn [55] généralise l'algorithme des k -moyennes en permettant la classification *floue* basée sur la théorie des ensembles flous. Bezdek s'y est intéressé [10, 11] et a développé cet algorithme. Dans le cas des c -moyennes floues, la fonctionnelle \mathcal{L} à minimiser est :

$$\mathcal{L} = J_w(\mathbf{x}, \mathbf{v} : \mathbf{y}) = \sum_{k=1}^n \sum_{i=1}^c (x_{ik})^w \|y_k - v_i\|_A^2$$

où n est le nombre de points à traiter, c le nombre de classes désirées, $w \in [1, +\infty]$ est le poids de *fuzzycation*, $\mathbf{v} = (v_1, \dots, v_c)$ est le vecteur des centres de classes, $\|\cdot\|_A$ est un produit scalaire où A est une matrice définie positive et $\mathbf{x} = [x_{ik}] \in \mathbb{R}^{c \times n}$, avec $x_{ik} \in [0, 1] \forall 1 \leq i \leq c$ et $1 \leq k \leq n$, est la c -partition floue de \mathbf{y} et doit vérifier :

$$\sum_{i=1}^c x_{ik} = 1 \text{ pour } 1 \leq k \leq n, \quad \sum_{i=1}^n x_{ik} > 0 \text{ pour } 1 \leq i \leq c$$

Xue et coll. utilise les FCM pour combiner le filtre moyen au filtre médian local afin de réaliser la segmentation locale de volumes IRM de cerveaux [179]. Pham et coll. ainsi que Jiang et coll. utilisent les inhomogénéités d'intensité des volumes IRM dans la fonctionnelle \mathcal{L} et obtiennent ainsi un FCM adaptatif qui permet une meilleur segmentation [83, 136, 135, 134].

Mean Shift

L'algorithme du Mean Shift, introduit par Fukunaga [62] puis remis au got du jour par Comaniciu [38], recherche le "mode" ou point de plus haute densité d'une distribution de données. Dans cet article, les auteurs décrivent les bases de leur méthode (estimation par noyau de Parzen) ainsi que deux principaux champs d'applications, à savoir recherche de mode et filtrage de données. Une méthode élégante pour localiser les maxima locaux d'une fonction de densité est la recherche des zéros de son gradient.

Le gradient de l'estimation non paramétrique par le noyau K_H est :

$$\hat{\nabla} f(x) = \nabla \hat{f}(x) = \frac{1}{n} \sum_{i=1}^n \nabla K_H(x - x_i)$$

Elle est dépendante de la forme du gradient du noyau. Avec un K_H de la forme :

$$K_H(\mathbf{x}) = |H|^{-1/2} K(H^{-1/2} \mathbf{x})$$

où H est la matrice de paramètre d'échelle et $|H|$ le déterminant de la matrice H , on a un gradient de la forme :

$$\nabla K_H(\mathbf{x}) = |H|^{-1/2} \cdot \nabla K(H^{-1/2} \mathbf{x})$$

Si le noyau K a comme profil la fonction k , définie telle que :

$$K(\mathbf{x}) = C_{k,d} \cdot k(\mathbf{x}^T \mathbf{x})$$


alors on obtient l'expression :

$$\nabla K_H(\mathbf{x}) = 2C_{k,d} |H|^{-1/2} H^{-1} \mathbf{x} k'(\mathbf{x}^T H^{-1} \mathbf{x})$$

En posant $g(x) = -k'(x)$ et après quelques manipulations, on obtient l'équation du gradient de l'estimation suivante :

$$\nabla \hat{f}(\mathbf{x}) = \frac{2C_{k,d} H^{-1}}{n|H|^{1/2}} \cdot \sum_{i=1}^n g(d^2(\mathbf{x}, \mathbf{x}_i, H)) \cdot \left[\frac{\sum_{i=1}^n g(d^2(\mathbf{x}, \mathbf{x}_i, H)) \cdot \mathbf{x}_i}{\sum_{i=1}^n g(d^2(\mathbf{x}, \mathbf{x}_i, H))} - \mathbf{x} \right]$$

où d représente la distance de Mahalanobis. Le but est de trouver les valeurs de \mathbf{x} pour lesquelles le vecteur gradient de l'estimation est nul. Celui-ci s'annule si et seulement si le vecteur entre crochets est nul. Ce vecteur, appelé vecteur *Mean Shift*, est donc proportionnel au gradient de l'estimation.



(a) IRM d'origine (Brain-Web)

(b) Vérité terrain

(c) Résultat de la segmentation

FIG. 7 – Résultats de segmentation obtenus par Mean Shift - tiré de [121].

La procédure de segmentation dans ce cadre est la suivante :

1. Considérer les images en terme de caractéristiques (via couleur, gradient, mesures de texture, etc.)

2. Choisir une répartition uniforme des fenêtres de recherche initiales.
3. Calculer le centroïde des données pour chaque fenêtre.
4. Centrer la fenêtre de recherche sur le centroïde de l'étape 3.
5. Répéter les étapes 3 et 4 jusqu'à convergence.
6. Fusionner les fenêtres se trouvant au même point final.
7. Grouper les données traversées par les fenêtres fusionnées.

Keselman et Micheli-Tzanakou ont montré dans [89] que cet algorithme était applicable pour l'extraction et la caractérisation de régions d'intérêts dans les images biomédicales. Mayer et coll. utilisent ce paradigme de manière adaptative pour segmenter les IRM cérébrales [121]. Jiménez-Alaniz et coll. proposent dans [84] de faire une estimation de densité non-paramétrique par un mean shift conjointement avec une carte de confiance de bords.

3.2.3 Classification Probabiliste Paramétrique

Mélange de Loïs

Le problème classique de la classification automatique est de considérer qu'un échantillon de données provienne d'un nombre de groupes inconnus a priori qu'il faut retrouver. Lorsqu'on part du postulat que ces groupes suivent une loi de probabilité (quelconque), alors on se place nécessairement dans le cadre des modèles de mélanges. Si, en plus, on considère que les lois que suivent les individus sont normales, alors on se place dans le cadre des modèles de mélanges gaussiens.

Par la suite, on notera \mathbf{x} , un échantillon composé de n individus $(\mathbf{x}_1, \dots, \mathbf{x}_n)$ appartenant à \mathbb{R}^p (*i.e.* caractérisés par p variables continues). Dans le cadre des modèles de mélanges gaussiens, on considère que ces individus appartiennent chacun à un des g (g étant fixé a priori) G_1, \dots, G_g suivant chacun une loi normale de moyenne $\boldsymbol{\mu}_k$, ($k = 1, \dots, g$) et de matrice de variance-covariance $\boldsymbol{\Sigma}_k$. D'autre part, en notant π_1, \dots, π_g les proportions des différents groupes, $\boldsymbol{\theta}_k = (\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$ le paramètre de chaque loi normale et $\boldsymbol{\Phi} = (\pi_1, \dots, \pi_g, \boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_g)$ le paramètre global du mélange, la loi mélange que suit l'échantillon peut s'écrire

$$g(\mathbf{x}, \boldsymbol{\Phi}) = \sum_{k=1}^g \pi_k f(\mathbf{x}, \boldsymbol{\theta}_k),$$

avec $f(\mathbf{x}, \boldsymbol{\theta}_k)$ la loi normale multidimensionnelle paramétrée par $\boldsymbol{\theta}_k$.

La principale difficulté de cette approche consiste à déterminer le meilleur paramètre $\boldsymbol{\Phi}$. Pour cela, on cherche habituellement le paramètre qui maximise la vraisemblance, donnée dans ce cas, par

$$L(\mathbf{x}; \boldsymbol{\Phi}) = \sum_{i=1}^n \log \left(\sum_{k=1}^g \pi_k f(\mathbf{x}_i, \boldsymbol{\theta}_k) \right).$$

Une fois l'estimation effectuée, il s'agit d'attribuer à chaque individu la classe à laquelle il appartient le plus probablement. Pour cela, on utilise la règle d'inversion de Bayes. D'après celle-ci, on a

$$P(G_k | \mathbf{x}) = \frac{P(\mathbf{x} | G_k) \cdot P(G_k)}{P(\mathbf{x})},$$

ce qui se traduit, dans notre cas, par

$$P(G_k | \mathbf{x}_i) = \frac{\pi_k f(\mathbf{x}_i, \boldsymbol{\theta}_k)}{\sum_{\ell=1}^g \pi_\ell f(\mathbf{x}_i, \boldsymbol{\theta}_\ell)}.$$

Il suffit alors d'attribuer chaque individu \mathbf{x}_i à la classe pour laquelle la probabilité a posteriori $P(G_k | \mathbf{x}_i)$ est la plus grande.

Bien que ce problème puisse sembler particulièrement hardu, l'algorithme EM [50] (espérance-maximisation), en anglais *Expectation-maximisation*, permet de lever la difficulté de la détermination de Φ : Espérance-Maximisation alterne des étapes d'évaluation de l'espérance (E), où l'on calcule l'espérance de la vraisemblance en tenant compte des dernières variables observées, et une étape de maximisation (M), où l'on estime le maximum de vraisemblance des paramètres en maximisant la vraisemblance trouvée à l'étape E. On utilise ensuite les paramètres trouvés en M comme point de départ d'une nouvelle phase d'évaluation de l'espérance, et l'on itère ainsi.

Afin de réduire le risque de tomber dans un maximum local de vraisemblance, Celeux et Diebolt proposent dans [27, 28] d'intercaler une étape stochastique de classification entre les étapes E et M. Hashimoto et coll. utilisent les sous-ensembles ordonnés pour améliorer l'EM [71]. L'EM est utilisé conjointement avec les champs de Markov par Li et coll. pour classifier les tissus cérébraux à partir d'image IRM de tenseurs [105]. Enfin, une version robuste et spatio-temporelle a été développée par At-Ali et coll. dans [1] en utilisant l'estimateur tamisé de vraisemblance [130]

3.2.4 Classification Probabiliste Non-Paramétrique

Champs Aléatoires de Markov

La classification par mélange de lois ne tient pas compte de la répartition spatial des voxels, pour ajouter cette information, on utilise les champs de Markov [63] qui modélisent les interactions entre un voxel et son voisinage. Notons x_s la valeur du descripteur au site s , $x^s = (x_s)_{t \neq s}$ la configuration de l'image excepté le point s , V_s le système de voisinage et $U(x) = \sum_{c \in C} U_c$ l'énergie globale de l'image (c'est la somme des potentiels de toutes les cliques). X est un champ de Markov si et seulement si :

$$P(X_s = x_s / x^s) = P(X_s = x_s / x_t, t \in V_s)$$

Autrement dit, le niveau de gris d'un site ne dépend que des niveaux de gris des pixels voisins. Les probabilités conditionnelles locales définies ci-dessus seront calculées par le théorème de Hammersley-Clifford grâce au champ de Gibbs donné par :

$$P(X = x) = \frac{1}{Z} \exp(-U(x))$$

où $Z = \sum_{x \in \Omega} \exp(-U(x))$. La définition du champ de Markov peut se réécrire alors :

$$P(X_s = x_s / x^s) = \frac{\exp(-U_s(x_s / V_s))}{\sum_{\xi \in E} \exp(-U_s(\xi / V_s))}$$

Le formalisme des champs de Markov permet d'effectuer une segmentation de l'image en prenant en compte les interactions avec les pixels voisins. On considère que les k régions que l'on souhaite segmenter forment une partition de l'image. Chaque région est représentée par une fonction caractéristique et identifiée par une étiquette dans $\{1, \dots, k\}$. Le but de la segmentation est d'estimer le champ des étiquettes X à partir d'une réalisation bruitée de l'image Y . La démarche de la segmentation peut se formaliser comme un problème d'estimation bayésienne.

On note S l'ensemble des sites de l'image, X le champ des étiquettes et Y le champ des observations (image de départ), on a donc dans le cas d'une image en 256 niveaux de gris :

$$X \begin{cases} S & \rightarrow \{1, \dots, k\} \\ s & \mapsto x_s \end{cases} \quad \text{et} \quad Y \begin{cases} S & \rightarrow [0, \dots, 255] \\ s & \mapsto y_s \end{cases}$$

En supposant que la réalisation de l'image est indépendante pour chaque pixel on a :

$$P(Y|X) = \prod_{s \in S} P(y_s|x_s)$$

Grâce au théorème de Bayes, il est possible d'exprimer la probabilité à posteriori d'un champ d'étiquettes étant donnée une observation Y . Connaissant Y , le champ des étiquettes est un champ aléatoire de distribution :

$$P(X|Y) = \frac{P(Y|X) \times P(X)}{P(Y)}$$

$P(Y)$ est un terme constant et ne nous intéresse pas pour l'estimation de X .

$P(X|Y)$ mesure la similarité de la classification aux données que l'on observe, c'est le terme d'attache aux données.

$P(X)$ est une probabilité a priori sur la distribution du champ d'étiquettes. On peut modéliser cet a priori grâce au modèle de Potts qui tend à favoriser des zones compactes et uniformes.

$$P(X) = \frac{1}{Z} \exp(-\beta \sum_{C=\{s,t\}} \phi(x_s - x_t))$$

β joue le rôle de coefficient de régularisation. Plus β est grand, plus la transition entre régions est pénalisée et plus les régions obtenues sont grandes.

Grâce au théorème de Hammersley-Clifford, on peut passer de la représentation probabiliste à une représentation en énergie. En prenant le logarithme des probabilités on obtient :

$$U(x) = \sum_{s \in S} \left[\frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}} + \frac{1}{2} \log(2\pi)\sigma_{x_s} \right] + \beta \sum_{C=\{s,t\}} \phi(x_s - x_t)$$

Le choix de la fonction ϕ influe grandement sur le résultat (notamment en ce qui concerne la convexité de $U(x)$), ainsi, le choix d'une forme quadratique pure qui correspond à la régularisation de Tikhonov [165, 166] pénalise les forts gradients, donnant alors une segmentation plus lisse.

Une estimation du champ des étiquettes peut se faire suivant le critère du Maximum a posteriori. Cela se fait en minimisant l'énergie grâce à l'algorithme des modes conditionnels itérés [163, 24] ou du recuit simulé. Une autre façon d'estimer le champ des étiquettes est d'utiliser une fonction de cot proportionnelle au nombre de pixels mal classifiés ce qui conduit à l'algorithme du maximum a posteriori de la marginale. Les effets de volumes partiels des IRM peuvent être gérés par des Champs de Markov Flous [150, 149, 180, 179]

Machine à Vecteurs de Support

Le principe des machines à vecteurs de support (en anglais Support Vector Machine ou SVM) [169] est simple : nous allons déplacer un problème complexe, souvent non-linéaire, dans un espace où le problème est linéaire ou, tout du moins, plus simple. Ainsi, on va projeter les données par une transformation ϕ dans un espace de dimension supérieure et calculer un séparateur dans cet espace de Hilbert séparable.

Ce séparateur est appelé *hyperplan* et les points de caractéristiques les plus proches de celui-ci définissent des plans appelés *vecteur de support*. Pour obtenir une segmentation robuste, il faut maximiser la marge, *i.e.* la distance entre l'hyperplan et les vecteurs de support.

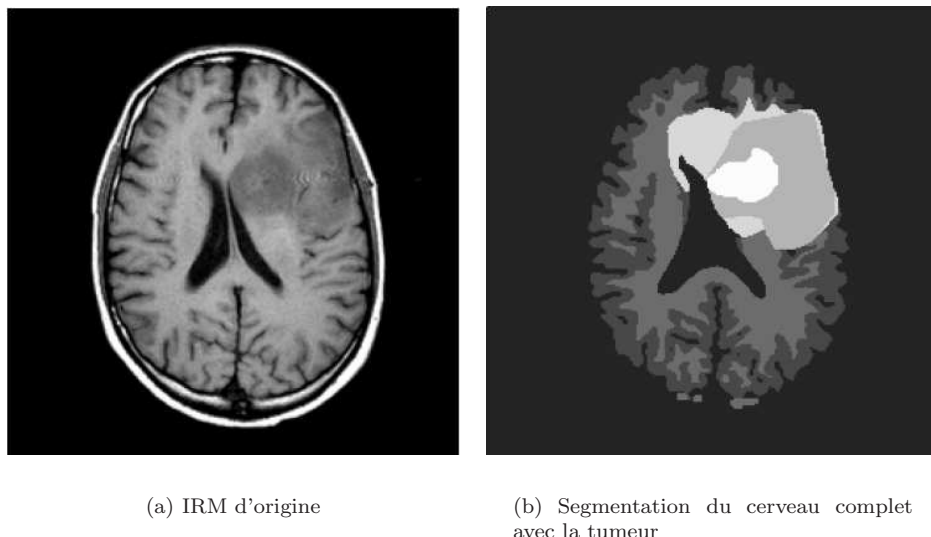


FIG. 8 – Segmentation par SVM - tiré de [101]

Ce principe de séparation de l'espace de caractéristiques s'applique très bien à la segmentation d'images [31]. Les machines à vecteurs de support sont utilisées pour la détection de visages dans une image [111, 157], pour segmenter les lésions de la matière blanche [97, 139] mais aussi pour la classification des cerveaux [98]. Lee et coll. proposent de les utiliser conjointement avec les champs de Markov pour créer les Support Vector Random Fields qui leur permettent de segmenter des tumeurs cérébrales [101].

3.3 Approches Structurelles

3.3.1 Gradient Morphologique

La morphologie mathématique, introduite par Matheron [120] et Serra [152], nous donne un cadre intéressant pour l'approche contour de la segmentation. Rappelons les définitions des deux opérations de bases que sont l'érosion et la dilatation.

Soit B un élément structurant et B_x cet élément centré en un pixel x . L'érosion consiste à poser en chaque pixel x d'un objet X , la question : " B_x est-il contenu entièrement dans X ?". L'ensemble des positions x correspondant à une réponse positive forme le nouvel ensemble $\epsilon_B(X)$, appelé érodé de X par B . Autrement dit :

$$\epsilon_B(X) = \{x | B_x \subseteq X\}$$


L'opération de dilatation se définit de manière analogue à l'érosion. En prenant le même élément structurant B , on pose pour chaque point z de l'image la question " B_z touche-t-il l'ensemble X ?". C'est à dire, y a-t-il une intersection non vide entre B_z et X ? L'ensemble des points de l'image correspondant aux réponses positives forme le nouvel ensemble $\delta_B(X)$, appelé dilaté de X par B .

C'est-à-dire :

$$\delta_B(X) = \{z | B_z \cap X \neq \emptyset\}$$

La différence symétrique entre l'image dilatée et érodée par le même élément structurant de taille unitaire donne le gradient morphologique qui est un opérateur de détection de contour et qui peut se résumer par l'équation :

$$mgrad_{1B}(X) = \delta_{1B}(X) / \epsilon_{1B}(X)$$



(a) IRM d'origine

(b) Résultat

FIG. 9 – Segmentation par gradient morphologique - tirée de [77].

Cette détection de contour par gradient morphologique est utilisée par Vachier et coll. [168] conjointement avec une ligne de partage des eaux pour la détection de tumeur sur des mammographies. De même Hsiao et coll. [77] proposent une méthode de segmentation de tumeur cérébrales basée sur le gradient morphologique et une étape de croissance et fusion de régions.

3.3.2 Ligne de Partage des Eaux

La morphologie mathématique consiste à comparer une structure inconnue (*i.e.* l'image que l'on étudie) à un ensemble de formes, les *éléments structurants*, dont on maîtrise toutes les caractéristiques. Ces comparaisons s'effectuent au moyen d'opérations booléennes telles que l'intersection et l'inclusion.

L'algorithme de la ligne de partage des eaux (LPE), proposé par Digabel et Lantuéjoul [53], utilise la description des images en termes géographiques. Une image peut en effet être perçue comme un relief si l'on associe le niveau de gris de chaque point à une altitude. Il est alors possible de définir la ligne de partage des eaux comme étant la crête formant la limite entre deux bassins versants.

Pour l'obtenir, il faut imaginer l'immersion d'un relief dans de l'eau, en précisant que l'eau ne peut pénétrer dans les vallées que par ses minima. La ligne de partage des eaux est représentée par les points où deux lacs disjoints se rejoignent au cours de l'immersion.

Une des difficultés à la mise en oeuvre de cette analogie intuitive est qu'elle laisse beaucoup de liberté quant à sa formalisation. Il existe deux classes principales d'implémentation : l'une est basée

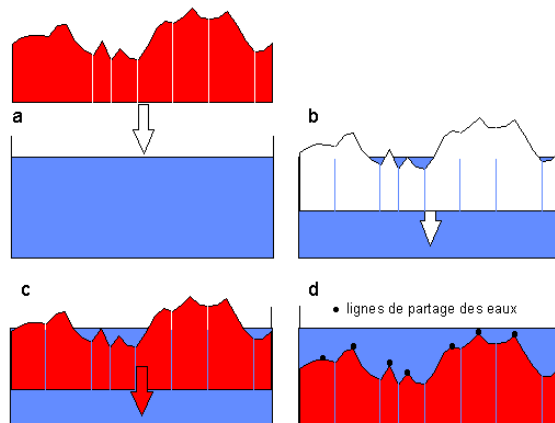


FIG. 10 – Principe de la Ligne de Partage des Eaux

sur un algorithme récursif d'immersion [171] et une autre basée sur l'utilisation de fonctions de distances géodésiques [123]. Leur définition algorithmique ainsi que leur analyse critique est donnée dans l'article de Roerdink et Meijster [144].

Cette technique est souvent associée à une méthode de fusion de régions puisqu'elle donne une sur-segmentation de l'image. On trouve cette utilisation conjointe dans [164] pour des images multi-dimensionnelles et notamment des IRM de cerveaux. Peng et coll. proposent d'utiliser une immersion multi-degré pour améliorer l'algorithme LPE [133]. Betser et coll. utilisent la LPE dans un contexte de segmentation hiérarchique [9].

3.4 Forme

Les approches basées sur la forme tendent à rechercher des régions qui dérivent d'une forme donnée comme *a priori*. Nous avons choisi de présenter quatre type de techniques qui en sont représentatives bien que d'autres puissent s'y ajouter.

3.4.1 Recalage d'atlas

L'utilisation d'un atlas consiste à appairer une image de référence (l'atlas) et l'image à traiter via un algorithme de mise en correspondance. On superpose alors les informations contenues dans l'image d'atlas et l'image à segmenter. Ainsi, les structures anatomiques constituant la matière grise peuvent être recalées simultanément et permettent d'obtenir une segmentation globale [37].

Dans le domaine de la neuro-imagerie, la référence est l'atlas stéréotaxique de Talairach [161, 162] qui permet de replacer le cerveau dans un référentiel - cf. figure 11 - à partir d'amers peu variables d'un individu à l'autre, en l'orientant et en appliquant des facteurs de proportions. L'atlas lui-même est plutôt voué au repérage des noyaux gris centraux pour la chirurgie mais le référentiel associé est devenu un standard et est utilisé dans de nombreuses méthodes de segmentation automatique en neuro-imagerie. Plus généralement, ce repère est utilisé à des fins de normalisation et de recalage inter-sujet comme l'explique Lemoine dans [104].




FIG. 11 – Repère proportionnel de Talairach.

Dawant, Hartmann et coll. utilisent le recalage d'atlas pour segmenter le cerveau, le cervelet et les noyaux caudés sur une série de volumes IRM [49] puis utilisent cette méthode pour quantifier des atrophies cérébrales [70]. Dans ces approches, l'hypothèse est que la topologie est la même entre l'atlas et le volume, ce qui limite la prise en compte de la variabilité anatomique.

D'autres approches utilisent le recalage pour initialiser ou guider le processus de segmentation [154, 4]. Cuadra et coll. [47] apportent un modèle *a priori* de croissance de lésion conjointement au recalage par atlas pour réaliser la segmentation de structures dans les IRM de cerveaux pathologiques. L'atlas peut être modélisé comme des cartes de probabilité de localisation des différents tissus ; c'est cette méthode, utilisée avec un algorithme de type *Expectation-Maximisation* que Van Leemput et coll. préconisent dans [102] afin de réaliser la segmentation et la correction de biais d'IRM cérébrales. Enfin, pour contre-balancer les problèmes de mauvaise segmentation obtenus lorsque les IRM ne sont pas acquises sur les mêmes plateformes, Han et coll. [69] introduisent une procédure de renormalisation d'intensité qui ajuste automatiquement l'intensité du modèle aux données entrées améliorant ainsi la précision de la segmentation.

3.4.2 Transformation dans un sous-espace

Un sous-espace est l'ensemble de toutes les approximations possibles d'un même signal à la résolution associée au sous-espace. A chaque étape de ces transformations, on élimine des détails et ainsi on se focalise sur la forme. L'analyse par ondelettes et par harmoniques sphériques sont par essence-même les techniques les plus représentatives de cette approche. On y trouvera aussi les Modèles Actifs de forme et d'Apparence qui sont apparentés par leur décomposition des variations de formes à une transformation dans un sous-espace déterminée sur le plan statistique.

Ondelettes

Cette technique repose sur un principe de décomposition en sous-bandes et de transformation mathématique par projection sur des bases orthogonales. L'analyse par ondelettes peut être en première approximation considérée comme une alternative de la Transformée de Fourier Rapide (en anglais *Fast Fourier transform* ou FFT). Là où la FFT décompose l'image en phase et en amplitude, les ondelettes la décompose en base orthogonale. Elle peut être vue comme une FFT dans laquelle la fenêtre d'analyse peut être optimisée dans sa forme et possède en outre la propriété essentielle d'opérer sur une durée variant avec la fréquence. Il en résulte des possibilités accrues de filtrage avec des temps de calcul raisonnables.

La transformée en ondelettes est définie par :

$$Wf(u, s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^* \left(\frac{t-u}{s} \right) dt$$

où l'atome de base y est une fonction de moyenne nulle, centrée au voisinage de 0 et d'énergie finie. La famille de vecteurs est obtenue par translation et dilatation de l'atome de base :

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi \left(\frac{t-u}{s} \right)$$

La fonction précédente est centrée au voisinage de u , comme l'atome de Fourier fenêtré. Si le centre de fréquence de y est h , le centre de fréquence de la fonction dilatée est en h/s

La transformée en ondelettes a donc une résolution temps-fréquence qui dépend de l'échelle s . Sous la condition

$$C_\psi = \int_0^{+\infty} \frac{|\hat{\psi}(w)|^2}{w} dw < +\infty$$

c'est une représentation complète, stable et redondante du signal ; en particulier, la transformée en ondelettes est inversible à gauche. La redondance se traduit par l'existence d'un noyau reproduisant.

Une ondelette est donc un signal oscillant dont la moyenne est nulle et dont l'énergie tend vers zéro à l'infini. Les ondelettes sont regroupées en familles de courbes formant chacune une base de l'espace vectoriel des signaux. Pour plus de détails, on pourra se reporter aux travaux de Mallat [114, 115].

A chaque étape on applique en fait dans la cellule de décomposition deux filtres : un passe-bas, dont sera issue une approximation A_{k-1} , et un passe-haut, dont on obtiendra les détails D_{k-1} . En procédant à une décimation d'ordre 2 sur A_{k-1} on pourra à l'étage suivant utiliser les mêmes filtres ce qui simplifie fortement l'architecture du système.

La décomposition en ondelettes est notamment utilisée par Wu et coll. dans [175] pour le recalage de volumes IRM multimodaux de cerveaux. Zhou et Ruan [184, 185] appliquent un seuillage multicontexte sur la transformée en ondelettes de l'histogramme pour déterminer la probabilité d'appartenance du voxel aux différents tissus considérés.

Hou et Koh [76] applique la méthode des c -moyennes floues avec un filtrage par ondelettes et compare cette méthode avec d'autres segmentations sur fantôme et données réelles. Nain et coll. ont présenté dans [129] une nouvelle représentation multi-échelle de forme basée sur les ondelettes sphériques et utilise ses propriétés pour réaliser la segmentation de structures cérébrales.

En dehors de l'imagerie médicale, on trouve les travaux de Choi et Baraniuk [32] qui utilisent les ondelette de Haar ainsi que ceux de Figueiredo pour tous types d'ondelettes [58]. On pourra trouver des méthodes intéressantes de segmentation et de caractérisation de texture par ondelettes de Gabor dans les travaux de Jain [80, 81] et Prabhakar [137] en biométrie des empreintes digitales.




FIG. 12 – Segmentation par ondelettes - tiré de [185]

Harmoniques Sphériques

On appelle harmoniques sphériques, les fonctions $Y_l^m(\theta, \varphi)$ définies sur la sphère unité, et orthonormées sur cette sphère avec la mesure uniforme dS sur la sphère. Puisqu'elles forment une base orthogonale de fonctions propres de l'opérateur laplacien sur la sphère unité, une fonction continue $f(\theta, \varphi)$ se décompose en une série :

$$f(\theta, \varphi) = \sum_{l=0}^{+\infty} \sum_{m=-l}^{+l} C_l^m \cdot Y_l^m(\theta, \varphi)$$

où l et m sont des indices entiers, C_l^m est un coefficient constant et souvent en mathématiques prend le nom de coefficient de Fourier généralisé relativement à cette base. En effet, le développement en harmoniques sphériques est l'équivalent, appliqué aux fonctions angulaires, du développement en séries de Fourier pour les fonctions périodiques.

Dans son article, Gerig [64] explique que la description en harmoniques sphériques est hiérarchique, globale, multi-échelle mais ne peut seulement représenter que les objets de topologie sphérique puisque les fonctions de base de la surface paramétrisée sont des harmoniques sphériques. Ces contraintes de topologie sphérique doivent donc être vérifiées au préalable par diverses méthodes parmi lesquelles on peut citer celle de Malandain [113].

Kelemen [88] a démontré que les harmoniques sphériques peuvent être utilisées pour exprimer les déformations d'une forme. Tronquer la série d'harmoniques sphériques à différents degrés donne des représentations de l'objet à différents niveaux de détails. Il utilise cette approche pour caractériser la forme des ventricules cérébraux. Golberg-Zimring et coll. utilisent les harmoniques sphériques pour approximer la forme des tumeurs cérébrales afin de les segmenter dans un contexte de neurochirurgie assistée par ordinateur [65].




FIG. 13 – Segmentation d'un oligodendrogliome par Harmoniques Sphériques - tiré de [65]

Modèle actif de Forme

Les Modèles actifs de forme (en anglais *Active Shape Models* ou ASM) [41] sont des modèles statistiques de la forme d'un objet qui se déforment itérativement pour s'adapter à un exemplaire de cet objet dans une nouvelle image. Les formes sont contraintes par un Modèle de Distribution de Points [43] (en anglais *Point Distribution Models* ou PDM). Celui-ci est obtenu par un jeu d'image d'entraînement qui montre différentes formes de cet objet. On calcule ensuite les principaux modes de variations par une analyse en composante principale, ce qui nous donnera les variations autorisées de la forme, constituant ainsi un sous-espace des formes possibles pour l'objet.

La forme moyenne est utilisée pour initialiser le processus puis elle est itérativement mise à jour selon deux étapes répétées jusqu'à convergence :

- On cherche le long de la normale aux points le meilleur appariement possible pour le modèle (*i.e.* on privilégie les arêtes)
- On met à jour les paramètres de la forme pour être le plus en adéquation avec le modèle.

Duta et coll. [56] ont utilisé ce paradigme avec une base de connaissance pour segmenter les images de volumes IRM de cerveaux. Shen et coll. ont ajouté des informations locales à ce modèle pour créer un ASM adaptatif [155]. Rousson et coll. se sont eux intéressés à la relation existant entre les ASM et les level sets [146, 147]. D'autres applications peuvent être trouvées, notamment la modélisation de sillons corticaux [44] et leur mise en correspondance [46] ou bien encore la modélisation des aires visuelles fonctionnelles [45]. Davatzikos et coll. proposent dans [48] d'utiliser les propriétés des transformées en ondelettes pour réaliser une segmentation par ASM hiérarchique, notamment dans le cadre des images biomédicales comme la segmentation du corps calleux.

La qualité de la segmentation étant très dépendante de l'initialisation, celle-ci doit se faire à une distance relativement faible de la cible. Pour améliorer son idée, Cootes a proposé d'inclure une information d'intensité de niveau de gris. Ce sont les Modèles Actifs d'Apparence que nous présentons ci-après.

Modèle Actif d'Apparence




FIG. 14 – Exemple de Modèle Actif de Forme - tiré de [56]

Les Modèles Actifs d'Apparence (en anglais *Active Appearance Model* ou AAM) [42, 40] sont une généralisation de l'approche ASM, mais utilisent toute l'information contenue dans la région d'image couverte par l'objet cible au lieu de ne la prendre qu'autour des arêtes modélisées.

Un AAM contient un modèle statistique de la forme et l'apparence de niveau de gris de l'objet d'intérêt et peut donc se généraliser à n'importe quel exemple valide. L'appariement d'une image implique de trouver les paramètres du modèle qui minimisent la différence entre l'image et un modèle synthétique projeté sur l'image.

On peut observer que s'éloigner chaque paramètre du modèle de la valeur correcte induit un motif particulier dans les résidus. Dans la phase d'apprentissage, l'AAM apprend un modèle linéaire de la relation entre le déplacement des paramètres et les résidus induits. Pendant la recherche, ces résidus sont mesurés et on utilise le modèle pour corriger les paramètres courants, permettant ainsi un meilleur appariement. Celui-ci est obtenu après seulement quelques itérations même si l'initialisation est pauvre.

Beichel et coll. proposent dans [6] d'utiliser le mean-shift pour caractériser les résidus et donner ainsi plus de robustesse à l'algorithme. Klemencic et coll. quant à eux utilisent l'AAM comme une étape de recalage en vue de la segmentation d'IRM de cerveaux [91]. Cootes et coll. [39] proposent en outre d'utiliser les AAM pour réaliser un recalage d'atlas.

3.4.3 Forme paramétrique

Le principe des approches par forme paramétrique est de faire évoluer un contour ou une surface vers les frontières de l'objet que l'on cherche à segmenter, d'où le nom de **contour actif**. Cette déformation est ici exprimée par des forces qui s'appliquent sur les points de contrôle du contour paramétré.

Contours Actifs

Les contours actifs, ou *snakes*, ont été introduits par Kass en 1987 [87] et sont toujours utilisés aujourd'hui sous des formes plus évoluées. L'idée sous-jacente est de déterminer la déformation d'un contour en minimisant une fonctionnelle énergétique qui traduit les forces appliquées aux points de contrôle du contour $\mathcal{C} : [a, b] \rightarrow \mathbb{R}^2$. La fonctionnelle associée au *snake* en 2D est :

$$E(\mathcal{C}(p)) = \alpha \int_a^b E_{int}(\mathcal{C}(p)) dp + \beta \int_a^b E_{don}(\mathcal{C}(p)) dp + \lambda \int_a^b E_{con}(\mathcal{C}(p)) dp$$

avec α , β et λ des constantes positives.

E_{int} est une contrainte de régularisation pour obtenir un contour lisse, E_{don} est le terme d'attache aux données qui dépend du gradient de l'image et E_{con} exprime des contraintes externes définies en lien avec l'application et favorisent un type de déformation donnée.

Par la technique de descente de gradient, cette fonctionnelle est minimisée pour aboutir aux équations d'Euler-Lagrange qui détermine l'évolution du contour. Cette formulation originelle est très sensible à l'initialisation et est facilement attirée par les minima locaux d'énergie. Pour contrer cela, Cohen [36] a proposé l'incorporation d'une énergie dite *de ballon* par l'ajout d'un terme E_{bal} dans l'équation précédente. Celle-ci devient donc :

$$E(\mathcal{C}(p)) = \alpha \int_a^b E_{int}(\mathcal{C}(p)) dp + \beta \int_a^b E_{don}(\mathcal{C}(p)) dp + \lambda \int_a^b E_{con}(\mathcal{C}(p)) dp + \delta \int_a^b E_{bal}(\mathcal{C}(p)) dp$$

où E_{bal} définit un potentiel de pression qui permet de "gonfler" ou de "dégonfler" le contour en fonction du signe de δ et rend le *snake* plus robuste à l'initialisation et au bruit sur l'image. Cette énergie compense aussi la tendance naturelle du *snake* à se rétracter en raison de la contrainte de régularisation. Le réglage du poids δ reste en revanche très dépendant de l'application visée et nécessite le plus souvent une intervention de l'utilisateur.

D'autres travaux se sont intéressés à l'utilisation de modes différents de paramétrisation tels que les spline snakes de Leitner et coll. [103] ou les plus récents B-splines [122] ou bien encore les Gaussiennes rationnelles [183]. Les récents travaux de Lecellier et coll. [100, 99], inspirée de ceux de Jehan-Besson [82], utilisent les contours actifs en y introduisant un *a priori* de forme.

Xu et Prince [176, 177] ont développé un nouveau type de *snake* qui permet une initialisation éloignée de l'objet et arrive à segmenter de façon correcte en levant l'écueil des concavités. Ce nouveau *snake* est basé sur un nouveau type de champ de force externe, appelé *gradient vector flow* ou GVF. Ce champ est calculé comme la diffusion spatiale du gradient d'une carte de bords (ou *edge map*). Combiné aux forces usuelles, ce GVF améliore grandement la qualité de la segmentation, notamment pour les images de coeur et de cerveau où les frontières sont très complexes.

3.4.4 Forme discrète

Le paradigme des *snakes* posant des problèmes de topologie (ils sont incapables de gérer les changements de topologies), d'autres techniques se sont développées en parallèle, il s'agit des contours actifs non-paramétriques, ou *implicites*, encore appelés **ensemble de niveau**. Ces travaux sont inspirés des théories de la propagation des fronts et des interfaces entre fluides et/ou solides de natures différentes sous l'action d'une force dépendant de leur courbure [153, 131].

Le contour \mathcal{C} - ou interface - de dimension n évolue ici selon une force telle que :

$$\frac{\partial \mathcal{C}}{\partial t} = F(\kappa) \mathbf{n}$$

où \mathbf{n} est le vecteur normal à l'interface, orienté vers l'extérieur, et κ la courbure.

Les ensembles de niveaux considère cette interface \mathcal{C} comme l'ensemble de niveau zéro d'une hypersurface de dimension $n + 1$, notée Ψ et définie par :

$$\Psi : \begin{cases} \mathbb{R}^n \times [0, \infty[& \rightarrow \mathbb{R} \\ (\mathbf{x}, t) & \mapsto \Psi(\mathbf{x}, t) \end{cases}$$

On obtient alors l'expression suivante pour l'interface :

$$\mathcal{C}(t) = \{\mathbf{x} \in \mathbb{R}^n \mid \Psi(\mathbf{x}(t), t) = 0\} \forall t \in [0, \infty[$$

On peut alors définir l'ensemble de niveau k , où $k \in \mathbb{Z}^+$:

$$\mathbf{x} \in \mathbb{R}^n \mid \Psi(\mathbf{x}(t), t) = k, \forall t \in [0, \infty[$$

On ne modélise pas directement l'évolution \mathcal{C} , on s'intéresse à l'évolution de Ψ en sachant qu'à chaque instant on pourra retrouver \mathcal{C} en prenant l'ensemble de niveau zéro de Ψ . On peut, en outre, calculer l'équation d'évolution de l'hypersurface par la formule de Hamilton-Jacobi, telle que \mathcal{C} soit toujours son ensemble de niveau zéro :

$$\frac{\partial \Psi}{\partial t} + F(\kappa) |\nabla \Psi| = 0$$

avec $\Psi(t = 0) = \Psi_0$ où $\Psi_0 : \mathbb{R}^{n+1} \rightarrow \mathbb{R}$ est une fonction telle que $\Psi_0(\mathcal{C}(0)) = 0$. C'est une équation de Hamilton-Jacobi dont on peut trouver une solution en utilisant les lois de conservation hyperboliques [153]. On notera notamment que Osher et Sethian ont défini la fonction de "vitesse" par $F(\kappa) = 1 - \epsilon \kappa$.

Cette formulation permet les changements de topologie sans implémentation particulière, il n'y a pas de paramétrisation du contour de l'interface, l'utilisation en dimension supérieure ou égale à 3 est aisée et on peut calculer les caractéristiques géométriques de l'interface \mathcal{C} implicitement représentés par Ψ . Ainsi, en 2D, la courbure locale est donnée par :

$$\kappa = \operatorname{div} \left(\frac{\nabla \Psi}{|\nabla \Psi|} \right) = \frac{\Psi_{yy} \Psi_x^2 - 2 \Psi_x \Psi_y \Psi_{xy} + \Psi_{xx} \Psi_y^2}{(\Psi_x^2 + \Psi_y^2)^{\frac{3}{2}}}$$

et le vecteur normal au contour par :

$$\mathbf{n} = \frac{\nabla \Psi}{|\nabla \Psi|}$$

Level Set Géométrique

Caselles et coll. [25] ont introduit un modèle géométrique des contours actifs formulé par des équations aux dérivées partielles d'évolution de courbes. Chaque point de la courbe se déplace dans la direction de son vecteur normal à une vitesse proportionnelle à la courbure.

$$F = -g(|\nabla I|)(c + \epsilon \kappa)$$

où g est une fonction décroissante qui ralentit le contour dans les zones de fort gradient, c est une force d'expansion du contour (à rapprocher de l'énergie de ballon des *snakes*), κ est la courbure locale du gradient et ϵ est un facteur de pondération.

Cette approche est une alternative à la minimisation d'énergie qui peut être vue comme la recherche de la solution d'une équation de Hamilton-Jacobi, et être ainsi résolue de façon efficace par la méthode des courbes de niveau de Osher et Sethian.

Faugeras et Keriven [57] ont montré qu'il était possible d'utiliser ce principe pour résoudre les problèmes de la stéréoscopie dans lequel la segmentation est une étape clef pour l'appariement des images. Paragios et Deriche [132] proposent son utilisation pour la détection et le suivi d'objet en mouvement, utilisant des méthodes d'accélération connues sous le nom de *Narrow Band* et *Fast Marching* [153]. Prinnet et Bailloeuil [138, 5] introduisent un *a priori* de forme spatio-temporel pour contraindre et orienter la segmentation par level set géométrique.

Level Set Géodésique

Caselles et coll. [26] ont par la suite proposé un problème équivalent de minimisation d'énergie fondé sur la recherche d'un chemin géodésique minimal dans un espace de Riemann, ce qui revient à minimiser la fonctionnelle suivante :

$$E(C) = \int_0^1 g(|\nabla I(C(p))|) |C'(p)| dp$$

On obtient alors l'équation suivante pour l'hypersurface Ψ :

$$\frac{\partial \Psi}{\partial t} + g(|\nabla I|) |\nabla \Psi| \kappa - \nabla g \cdot \nabla \Psi = 0$$

Cette formulation, grâce au terme ∇g améliore la robustesse aux hétérogénéités de gradient le long de la frontière. Dans la cas où la fonction g n'est pas exactement nulle sur le contour, la segmentation est améliorée. En outre, ce terme ∇g , qui attire l'interface vers la frontière de la cible de segmentation, réduit la nécessité d'utiliser une force de type ballon pour contrer la rétraction du contour.




FIG. 15 – Segmentation par Level Set - tiré de [33]

Baillard et coll. ont appliqué cette méthode à la segmentation et au recalage d'image médicale 3D [4, 3]. Goldenberg et coll. ont proposé une méthode rapide de contours actifs géodésique dans [66] basée sur le schéma AOS (*additive operator splitting*) de Weickert-Romeney-Viergever. Chan et Vese [29] ont développé une amélioration de la version de base permettant ainsi de s'affranchir des problèmes observés lors de la segmentation de structures dont les contours sont doux. Juan et coll. propose dans [86] d'introduire un élément stochastique dans l'évolution du contour, permettant

ainsi de ne pas rester bloqué dans un minimum local. Tsai et coll. se sont intéressés dans [167] à l'apport d'un a priori de forme dans cette formulation des level sets géodésiques. Enfin, Ciofolo et coll. ont montré l'intérêt d'utiliser une commande floue pour combiner les level sets avec différents a priori pour la segmentation de structures cérébrales [35, 33, 34].

3.5 Théorie des Graphes

Dans les approches utilisant la théorie des graphes, l'idée directrice est de créer un graphe à partir de l'image selon des procédés assez simples et de travailler sur ces graphes, pouvant ainsi utiliser toute la panoplie d'outils développés dans le cadre de cette théorie. Un travail relativement important sera de valuer les arêtes puisque ce sont elles qui permettront de donner les caractéristiques de l'image à notre graphe.

Nous verrons deux méthodes : celle qui utilisent les hypergraphes (une famille de graphe aux caractéristiques insolites) et la méthode de coupe minimale de graphe, héritée des travaux d'optimisation de flux.

3.5.1 Hypergraphes

Les hypergraphes, introduit par Claude Berge en 1969 [7] généralisent la notion de graphe dans le sens où les arêtes ne relient plus un ou deux sommets, mais un nombre quelconque de sommets (compris entre un et le nombre de sommets de l'hypergraphe).

Soient $V = \{v_1, v_2, \dots, v_n\}$ un ensemble, $E = \{E_1, E_2, \dots, E_m\}$ une famille de parties de V , avec $(m, n) \in \mathbb{N}^*2$ deux entiers non nuls.

Un hypergraphe H est un couple (V, E) tel que :

$$\forall i \in ([1, m] \cap \mathbb{N}) \quad E_i \neq \emptyset$$

$$\bigcup_{i=1}^m E_i \subseteq V$$

A l'instar des graphes classiques, on dit que :

- Les éléments de V sont les *sommets* de H .
- Le nombre de sommets n est l'*ordre* de l'hypergraphe.
- Les éléments de E sont les arêtes ou *hyper-arêtes* de H .

Un apport intéressant pour le traitement d'image est la notion d'*hypergraphe de voisinage*. Dans cet hypergraphe, les sommets sont les pixels de l'image et les hyper-arêtes relient les pixels voisins. En ajoutant un paramètre de sélection sur la distance colorimétrique (*i.e.* les hyper-arêtes ne contiennent que les pixels de couleurs "proches"), on obtient un hypergraphe de voisinage colorimétrique qui nous donne une notion de gradient d'intensité. D'autres critères peuvent être employés pour créer les hyper-arêtes, permettant ainsi la création d'hypergraphes de voisinage adaptatifs [21, 30].

Bretto et coll. proposent dans [20] une revue de l'apport des hypergraphes dans le traitement d'images et notamment dans la segmentation et la détection de contours par l'utilisation des familles d'arêtes intersectantes dites *étoiles*. La caractéristique de ces *étoiles* est que leur intersection est non nulle, on peut alors exploiter cet ou ces élément(s) commun(s) comme critère de sélection. Rital et coll. [143, 141] propose d'utiliser la partition multi-échelle de l'hypergraphe de voisinage colorimétrique d'une image pour réaliser la segmentation, aussi bien sur des images 2D que 3D, en couleurs ou en niveaux de gris. L'application des hypergraphes dans la segmentation des tissus cérébraux est notamment visible dans [143, 142].




FIG. 16 – Exemple d'hypergraphe - par Claudio Rocchini

3.5.2 Graph Cuts

Tout comme les méthodes de type *contours actifs*, la segmentation par *Graph Cut* est une méthode agissant par minimisation d'énergie. Cette énergie est de la forme :

$$E(x) = \sum D_i(x_i) + \sum R_{ij}(x_i, x_j)$$

où D_i représente l'attache aux données et R_{ij} est un terme de régularisation portant sur les pixels voisins. Greig et al. ont montré que cette minimisation (de type estimation du maximum a posteriori d'un champ aléatoire de Markov) peut être réalisée par la coupe minimale d'un graphe à deux noeuds terminaux pour la restauration d'image binaire [67]. Ces résultats n'ont pas été remarqués pendant près de 10 ans principalement parce que cette restauration d'image binaire semblait d'une portée limitée mais à la fin des années 90, des travaux ont réutilisé cette méthode dite "S-T Graph Cut" pour des problèmes non-binaires, notamment en stéréo-vision [148] et en segmentation [19]. L'intérêt principal de cette méthode est l'assurance d'arriver à un minimum global. Kolmogorov et Zabih ont montré dans [95] quelles sont les fonctionnelles minimisables par les Graph Cuts.

Cette méthode repose sur les graphes de voisinage. C'est-à-dire que chaque pixel de l'image (cet ensemble est noté \mathcal{P}) devient un noeud du graphe et les arêtes issues de ce noeud rejoignent les noeuds représentant les pixels voisins. Ces arêtes sont valuées et leur valeur est d'autant plus petite que la dissimilarité entre les pixels voisins est grande. On adjoint à ce graphe deux noeuds spéciaux - ou *terminaux* - liés respectivement à l'objet (ce terminal est appelé *source* et noté S) et au fond (c'est le *puits*, noté T). Le choix du système de voisinage \mathcal{N} influe grandement sur la complexité du graphe.

Une coupe de graphe est une bi-partition des sommets, considérée comme l'ensemble des arêtes qui vont d'une partie à l'autre. La coupe de poids minimale est celle dont la somme de la valeur des arêtes est minimale et cette valeur est égale au flot maximal transistant par ce graphe. Les problèmes de calcul de flot maximal étant bien connus et résolus, on peut alors utiliser toute la gamme d'algorithmes déjà existant dont Ford-Fulkerson [60] et Dinic [54].

Le terme de régularisation est représenté par les arêtes entre noeuds (appelées *n-liens*), il traduit la notion de régionalité et le terme d'attache aux données est codé par les arêtes entre les terminaux et les noeuds (appelés *t-liens*), il traduit les propriétés de contour. La coupe minimale obtenue est alors une surface pour notre problème.

La méthode classique, décrite notamment par Boykov et Jolly dans [14, 16, 15], utilise à la fois des contraintes rigides et non-rigides. L'utilisateur sélectionne des pixels de l'objet à segmenter et




FIG. 17 – Coupe Minimale de Graphe - d'après Mickal Péchaud.

des pixels du fond (ce sont les graines). Ces pixels sont alors reliés de façon rigide aux noeuds terminaux; les graines-objet (notées \mathcal{O}) étant reliés au noeud source et les graines-fond (notées \mathcal{F}) au noeud puits. La valeur de ces t -liens doit être suffisamment grande pour s'assurer qu'ils ne fassent pas partie de la coupe. Ces graines servent ensuite à calculer des distributions d'intensité de l'objet $P(I|\mathcal{O})$ et du fond $P(I|\mathcal{F})$ et les t -liens de chaque pixel non graine sont calculés en fonction de ceux-ci (contraintes non-rigides). Enfin, les n -liens sont fonction du gradient. On peut résumer tout cela par un tableau :

Arête	Cas	Poids
$\{p, q\}$	$\{p, q\} \in \mathcal{N}$	$R_{\{p, q\}}$
$\{p, S\}$	$p \in \mathcal{F}$	0
	$p \in \mathcal{O}$	K
	$p \in \mathcal{P}, p \notin \mathcal{O} \cup \mathcal{F}$	$D_p(\text{"fond"})$
$\{p, T\}$	$p \in \mathcal{F}$	K
	$p \in \mathcal{O}$	0
	$p \in \mathcal{P}, p \notin \mathcal{O} \cup \mathcal{F}$	$D_p(\text{"objet"})$

où

$$K = 1 + \max_{p \in \mathcal{P}} \sum_{q: \{p, q\} \in \mathcal{N}} R_{\{p, q\}}$$

Le terme de régularisation est une fonction *ad-hoc* de pénalité de contour :

$$R_{\{p, q\}} \propto \exp\left(-\frac{I_p - I_q}{2\sigma^2}\right) \cdot \frac{1}{\text{dist}(p, q)}$$

avec I_p l'intensité du pixel p .

Enfin, le terme d'attache aux données est l'opposé de la log-vraisemblance aux distributions calculées précédemment :

$$D_p(\text{"fond"}) = -\ln P(I_p|\mathcal{F})$$

$$D_p(\text{"objet"}) = -\ln P(I_p|\mathcal{O})$$

Cette méthode est utilisée dans la comparaison d'algorithmes de calcul de coupe minimale dans [18]. En terme de qualité les algorithmes testés sont équivalents mais en terme de rapidité, l'algorithme proposé par Boykov est plus rapide que ceux testés (dont l'algorithme Dinic). Les

résultats de la segmentation par la méthode Boykov-Jolly et l'algorithme Boykov-Kolmogorov sont visibles sur la figure 18.




FIG. 18 – Graph Cut sur une photo de groupe - tiré de [18]

Boykov et Kolmogorov mélangent les bénéfices des Graph Cuts et des contours actifs géodésiques dans [17]. Ils y montrent notamment qu'un voisinage étendu permet à la valeur de la coupe de s'approcher de la longueur du contour correspondant pour toute métrique riemannienne anisotrope.

Xu et coll. proposent dans [178] une approche de contours actifs par Graph Cuts. Le principe est le même que précédemment si ce n'est que le point de départ est un contour approximatif qui est étendu en bande étroite. Son côté intérieur est contraint comme source et son côté extérieur comme puits. En appliquant itérativement jusqu'à convergence l'algorithme de calcul de coupe minimale, on s'assure de l'obtention d'un minimum global dans la bande. Toujours dans l'esprit d'utilisation de bande étroite, Lombaert et coll. utilisent une approche multi-échelle dans [110]. Le calcul du Graph Cut est effectué sur une image basse résolution puis étendu en bande étroite sur l'image de résolution supérieure, en itérant ainsi jusqu'à l'image d'origine. Les résultats obtenus sont similaires à ceux de Boykov et Jolly pour des temps encore meilleurs.

Zabih et Kolmogorov ont appliqué le paradigme EM au Graph cut dans [182]. Ainsi, dans la phase E, les clusters étant fixés, on utilise les Graph Cuts pour classifier les pixels ; à l'étape M, on fixe l'étiquetage et ce sont les paramètres de descriptions des clusters qui sont optimisés. Dans la même approche, on peut citer Rother et coll. [145] ainsi que Blake et coll. [12] qui utilisent des modèles paramétriques du fond et de l'objet, notamment des mélanges de gaussiennes. Juan et Keriven [85] rajoutent à ces méthodes la notion de α -matting pour la zone où les deux objets cohabitent par transparence.

Freedman et Zhang proposent dans [61] d'introduire un *a priori* de forme dans la formulation classique en ajoutant un terme de distance à une forme prédéfinie dans le terme de régularisation. Song et coll. [160] préfèrent un *a priori* d'atlas par l'ajout d'un terme de probabilité d'appartenance à un tissu eu terme d'attache aux données.

Boykov et Funka-Lea ont montré, dans [13], l'optimalité de la solution apportée par les Graph Cuts ainsi que l'apport des graphes dirigés par rapport aux graphes non-dirigés.

Enfin, Weldeslassie et Hamarneh ont étendu les Graph Cuts aux images DTI dans [172] et ont notamment introduit une mesure de similarité robuste pour valuer les arêtes du graphe.

4 Conclusion

A travers ce document, nous avons proposé un état de l'art des différentes techniques de segmentation d'images cérébrales et notamment des IRM. Puisque la qualité du résultat est intrinsèquement subjective et que la finalité d'utilisation de la segmentation obtenue influe sur la perception de qualité de ce résultat, le choix d'une technique plutôt qu'une autre est assez ardu.

Le lecteur attentif aura néanmoins remarqué une certaine évolution des techniques au cours du temps. Ainsi, les plus anciennes utilisaient préférentiellement les observations brutes et les informations qu'elles contenaient alors que les techniques actuelles ont tendance à introduire de plus en plus de connaissances *a priori*, se basant ainsi sur une véritable modélisation du cerveau pour accroître la qualité de la segmentation.

Grace à l'arrivée de machines de plus en plus puissantes, la capacité de calcul s'est accrue et il est désormais possible d'utiliser des techniques gourmandes en ressources mais d'une qualité indéniable. La problématique de la segmentation s'est donc peu à peu muée en un véritable travail d'optimisation des techniques. Ainsi, les méthodes de segmentation par équations aux dérivées partielles et les méthodes basées sur les Graph Cuts connaissent un engouement sans précédent et cette dynamique de recherche a permis une amélioration très poussée de la segmentation, aussi bien en temps de calcul qu'en qualité.

Références

- [1] L. AT-ALI, S. PRIMA, P. HELLIER, B. CARSIN, G. EDAN et C. BARILLOT : STREM : a robust multidimensional parametric method to segment MS lesions in MRI. *Dans International Conference on Medical Image Computing and Computer-Assisted Intervention*, volume 3749 de *Lecture Notes in Computer Science*, pages 409–416. Springer Berlin / Heidelberg, octobre 2005.
- [2] J. BABAUD, A. WITKIN, M. BAUDIN et R. DUDA : Uniqueness of the gaussian kernel for scale-space filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(1):26–33, 1986.
- [3] C. BAILLARD, C. BARILLOT et P. BOUTHEMY : Robust adaptative segmentation of 3D medical images with level sets. Rapport de Recherche 4071, INRIA, novembre 2000.
- [4] C. BAILLARD, P. HELLIER et C. BARILLOT : Segmentation of brain 3D MR images using level sets and dense registration. *Medical Image Analysis*, 5(3):185 – 194, 2001.
- [5] T. BAILLOEUL, V. PRINET, B. SERRA, P. MARTHON et A. RANGARAJAN : Spatio-temporal prior shape constraint for level set segmentation. *Dans Energy minimization methods in computer vision and pattern recognition*, volume 3757 de *Lecture notes in computer science*, pages 503–519. Springer Berlin / Heidelberg, novembre 2005.
- [6] R. BEICHEL, H. BISCHOF, F. LEBERL et M. SONKA : Robust active appearance models and their application to medical image analysis. *IEEE Transactions on Medical Imaging*, 24(9):1151–1169, septembre 2005.
- [7] C. BERGE : *Graphes et hypergraphes*. Dunod, 1969.
- [8] F. BERGHOLM : Edge focusing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(6):726–741, 1987.
- [9] J. BETSER, S. DELEST et R. BON : Unbiased watershed hierarchical 3D segmentation. *Dans Visualization, Imaging, and Image Processing*, 2005.
- [10] J. BEZDEK : *Pattern Recognition with Fuzzy Objective Function Algorithms*. Kluwer Academic Publishers, 1981.
- [11] J. BEZDEK, J. KELLER, N. PAL et R. KRISNAPURAM : *Fuzzy Models And Algorithms For Pattern Recognition And Image Processing*. Kluwer Academic Publishers, 1995.
- [12] A. BLAKE, C. ROTHER, M. BROWN, P. PÉREZ et P. TORR : Interactive image segmentation using an adaptive GMMRF model. *Dans European Conference on Computer Vision*, pages 428–441, 2004.
- [13] Y. BOYKOV et G. FUNKA-LEA : graph cuts and efficient n-d images segmentation. *International Journal of Computer Vision*, 70(2):109–131, novembre 2006.
- [14] Y. BOYKOV et M.-P. JOLLY : Interactive organ segmentation using graph cuts. *Dans International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 276–286. Springer-Verlag, 2000.
- [15] Y. BOYKOV et M.-P. JOLLY : Demonstration of segmentation with interactive graph cuts. *Dans International Conference on Computer Vision*, volume 2, pages 741–741, juillet 2001.
- [16] Y. BOYKOV et M.-P. JOLLY : Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images. *Dans International Conference on Computer Vision*, volume 1, pages 105–112, juillet 2001.

- [17] Y. BOYKOV et V. KOLMOGOROV : Computing geodesics and minimal surfaces via graph cuts. *Dans International Conference on Computer Vision*, volume 1, pages 26–33, 2003.
- [18] Y. BOYKOV et V. KOLMOGOROV : An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(9):1124–1137, septembre 2004.
- [19] Y. BOYKOV, O. VEKSLER et R. ZABIH : Fast approximate energy minimization via graph cuts. *Dans IEEE International Conference on Computer Vision*, volume 1, pages 377–384, septembre 1999.
- [20] A. BRETTO, H. CHERIFI et D. ABOUTAJDINE : Hypergraph imaging : an overview. *Pattern Recognition*, 35(3):651–658, 2002.
- [21] A. BRETTO et L. GILLIBERT : Hypergraph-based image representation. *Dans Graph-based Representations in Pattern Recognition*, pages 1–11, 2005.
- [22] J. CANNY : Finding edges and lines in images. Rapport de Recherche, Massachusetts Institute of Technology, 1983.
- [23] J. CANNY : A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8:679–714, 1986.
- [24] A. CAPELLE, O. ALATA, C. FERNANDEZ, S. LEFEVRE et J.C. FERRIE : Unsupervised segmentation for automatic detection of brain tumors in MRI. *Dans International Conference on Image Processing*, volume 1, pages 613–616, septembre 2000.
- [25] V. CASELLES, F. CATTE, T. COLL et F. DIBOS : A geometric model for active contours in image processing. *Numerische Mathematik*, 66(1):1–31, octobre 1993.
- [26] V. CASELLES, R. KIMMEL et G. SAPIRO : Geodesic active contours. *International Journal of Computer Vision*, 22(1):61–79, 1997.
- [27] G. CELEUX et D. DIEBOLT : The SEM algorithm : a probabilistic teacher algorithm derived from the em algorithm for the mixture problem. *Computational Statistics Quarterly*, 2(1):73–82, 1985.
- [28] G. CELEUX et G. GOVAERT : A classification EM algorithm for clustering and two stochastic versions. Rapport de Recherche 1364, Inria, 1991.
- [29] T. CHAN et L. VESE : Active contours without edges. *IEEE Transactions on Image Processing*, 10(2):266–277, février 2001.
- [30] S. CHASTEL, P. COLANTONI et A. BRETTO : Displaying image neighborhood hypergraphs line-graphs. *Dans International Conference on Discrete Geometry for Computer Imagery*, pages 124–135. Springer-Verlag, 2002.
- [31] Q.-Y. CHEN et Q. YANG : Segmentation of images using support vector machines. *Dans International Conference on Machine Learning and Cybernetics*, volume 5, pages 3304–3306, août 2004.
- [32] H. CHOI et R. BARANIUK : Image segmentation using wavelet-domain classification. *Dans SPIE Conference on Mathematical Modeling, Bayesian Estimation, and Inverse Problem*, juillet 1999.
- [33] C. CIOFOLO : *Segmentation de formes guide par des modles en neuro-imagerie - Intgration de la commande floue dans une mthode de segmentation par ensembles de niveau*. Thèse de doctorat, Universit de Rennes I - IFSIC - Ecole doctorale Matisse, décembre 2005.

- [34] C. CIOFOLO et C. BARILLOT : Brain segmentation with competitive level sets and fuzzy control. *Dans Information Processing in Medical Imaging*, volume 3565 de *Lecture Notes in Computer Science*, pages 333–344. Springer Berlin / Heidelberg, 2005.
- [35] C. CIOFOLO, C. BARILLOT et P. HELLIER : Combining fuzzy logic and level set methods for 3D MRI brain segmentation. *Dans IEEE International Symposium on Biomedical Imaging : Macro to Nano*, volume 1, pages 161–164, avril 2004.
- [36] L. COHEN : On active contour models and balloons. *Computer Vision, Graphics, and Image Processing*, 53(2):211–218, 1991.
- [37] D. COLLINS et C. EVANS : ANIMAL : validation and applications of non-linear registration-based segmentation. *International Journal of Pattern Recognition and Artificial Intelligence*, 11(8):1271–1294, décembre 1997.
- [38] D. COMANICIU et P. MEER : Mean shift : a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5):603–619, mai 2002.
- [39] T. COOTES, C. BEESTON, G. EDWARDS et C. TAYLOR : A unified framework for atlas matching using active appearance models. *Dans IEEE International Conference on Information Processing in Medical Imaging*, volume 1613, pages 322–333, 1999.
- [40] T. COOTES, G. EDWARDS et C. TAYLOR : Active appearance models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(6):681–685, 2001.
- [41] T. COOTES et C. TAYLOR : Active shape models - smart snakes. *Dans Proceedings of British Machine Vision Conference*, 1992.
- [42] T. COOTES et C. TAYLOR : Statistical models of appearance for medical image analysis and computer vision. *Dans SPIE Medical Imaging*, 2001.
- [43] T. COOTES, C. TAYLOR, D. COOPER et J. GRAHAM : Training models of shape from sets of examples. *Dans Proceedings of British Machine Vision Conference*, pages 266–275. Springer, 1992.
- [44] I. COROUGE : *Modélisation Statistique de formes en imagerie crbrale*. Thèse de doctorat, Université de Rennes I - IFSIC - Ecole doctorale Matisse, avril 2003.
- [45] I. COROUGE, M. DOJAT et C. BARILLOT : Statistical shape modeling of low level visual area borders. *Medical Image Analysis*, 8(3):353–360, 2004.
- [46] I. COROUGE, P. HELLIER, B. GIBAUD et C. BARILLOT : Interindividual functional mapping : a nonlinear local approach. *NeuroImage*, 19(4):1337–1348, 2003.
- [47] M. CUADRA, C. POLLO, A. BARDERA, O. CUISENAIRE, J.-G. VILLEMURE et J.-P. THIRAN : Atlas-based segmentation of pathological MR brain images using a model of lesion growth. *IEEE Transactions on Medical Imaging*, 23(10):1301–1314, octobre 2004.
- [48] C. DAVATZIKOS, X. TAO et D. SHEN : Hierarchical active shape models, using the wavelet transform. *IEEE Transactions on Medical Imaging*, 22(3):414–423, mars 2003.
- [49] B. DAWANT, S. HARTMANN, J. P. THIRION, F. MAES, D. VANDERMEULEN et P. DEMAEREL : Automatic 3-D segmentation of internal structures of the head in MR images using a combination of similarity and free-form transformations : Part I, Methodology and validation on normal subjects. *IEEE Transactions on Medical Imaging*, 18(10):909–916, octobre 1999.
- [50] A. DEMPSTER, N. LAIRD et D. RUBIN : Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society*, 39(1):1–38, 1977.

- [51] R. DERICHE : Optimal edge detection using recursive filtering. *Dans International Conference on Computer Vision*, 1987.
- [52] R. DERICHE : Using Canny's criteria to derive a recursively implemented optimal edge detector. *The International Journal of Computer Vision*, 1(2):167–187, mai 1987.
- [53] H. DIGABEL et C. LANTUJOL : Iterative algorithm. *Quantitative analysis of microstructures in materials sciences*, 1:85–99, 1978.
- [54] E. DINIC : Algorithm for solution of a problem of maximum flow in networks with power estimation. *Soviet Mathematics Doklady*, 11:1277–1280, 1970.
- [55] J. DUNN : A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, 3:32–57, 1973.
- [56] N. DUTA et M. SONKA : Segmentation and interpretation of MR brain images using an improved knowledge-based active shape model. *Dans Information Processing in Medical Imaging*, pages 375–380, 1997.
- [57] O. FAUGERAS et R. KERIVEN : Variational principles, surface evolution, PDEs, level set methods, and the stereo problem. *IEEE Transactions on Image Processing*, 7(3):336–344, mar 1998.
- [58] M. FIGUEIREDO : Bayesian image segmentation using wavelet-based priors. *Dans IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 437–443, 2005.
- [59] L. FLORACK et A. KUIJPER : The topological structure of scale-space images. *Journal of Mathematical Imaging and Vision*, 12(1):65–79, 2000.
- [60] L. FORD et D. FULKERSON : *Flows in Network*. Princeton University Press, 1962.
- [61] D. FREEDMAN et T. ZHANG : Interactive graph cut based segmentation with shape priors. *Dans IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 755–762, juin 2005.
- [62] K. FUKUNAGA et L. HOSTETLER : The estimation of the gradient of a density function with applications in pattern recognition. *IEEE Transactions on Information Theory*, IT-21:32–40, 1975.
- [63] S. GEMAN et D. GEMAN : Stochastic relaxation, Gibbs distribution, and the Bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6:721–741, 1984.
- [64] G. GERIG, M. STYNER, D. JONES, D. WEINBERGER et J. LIEBERMAN : Shape analysis of brain ventricles using SPHARM. *Dans IEEE Workshop on Mathematical Methods in Biomedical Image Analysis*, pages 171–178, décembre 2001.
- [65] D. GOLDBERG-ZIMRING, H. AZHARI, S. MIRON et A. ACHIRON : 3-D surface reconstruction of multiple sclerosis lesions using spherical harmonics. *Magnetic Resonance in Medicine*, 46(4):756–766, octobre 2001.
- [66] R. GOLDENBERG, R. KIMMEL, E. RIVLIN et M. RUDZSKY : Fast geodesic active contours. *IEEE Transactions on Image Processing*, 10(10):1467–1475, octobre 2001.
- [67] D. GREIG, B. PORTEOUS et A. SEHEULT : Exact maximum a posteriori estimation for binary images. *Journal of the Royal Statistical Society*, 51(2):271–279, 1989.
- [68] J. HADAMARD : *Le Problème de Cauchy et les Equations aux Dérivées Partielles Linéaires Hyperboliques*. Herman et Cie, 1932.

- [69] X. HAN et B. FISCHL : Atlas renormalization for improved brain MR image segmentation across scanner platforms. *IEEE Transactions on Medical Imaging*, 26(4):479–486, avril 2007.
- [70] S. HARTMANN, M. PARKS, P. MARTIN et B. DAWANT : Automatic 3-D segmentation of internal structures of the head in MR images using a combination of similarity and free-form transformations : Part II, Validation on severely atrophied brains. *IEEE Transactions on Medical Imaging*, 18(10):917–926, octobre 1999.
- [71] A. HASHIMOTO et H. KUDO : Ordered-subsets EM algorithm for image segmentation with application to brain MRI. *Dans IEEE Nuclear Science Symposium Conference Record*, 2000.
- [72] S. HAYKIN : *Neural networks : a comprehensive foundation - 2nd Edition*. Prentice Hall, 1998.
- [73] R. HENKEL : Segmentation in scale space. *Dans Computer Analysis of Images and Patterns*, pages 41–48, 1995.
- [74] S. HOROWITZ et T. PAVLIDIS : Picture segmentation by a directed split-and-merge procedure. Rapport de Recherche, Departement of Electrical Engineering, Princeton University, 1975.
- [75] S. HOROWITZ et T. PAVLIDIS : Picture segmentation by a tree traversal algorithm. *Journal of The Association for Computing Machinery*, 23(3):368–388, avril 1976.
- [76] Z. HOU et T. KOH : Wavelet shrinkage prefiltering for brain tissue segmentation. *Dans International Conference of the Engineering in Medicine and Biology Society*, pages 1604–1606, septembre 2005.
- [77] Y.-T. HSIAO, C.-L. CHUANG, J.-A. JIANG et C.-C. CHIEN : A contour based image segmentation algorithm using morphological edge detection. *Dans IEEE International Conference on Systems, Man and Cybernetics*, volume 3, pages 2962–2967, 10-12 Oct. 2005.
- [78] R. HULT : Grey-level morphology combined with an artificial neural networks approach for multimodal segmentation of the hippocampus. *Dans International Conference on Image Analysis and Processing*, pages 277–282, 2003.
- [79] R. HUMMEL et B. GIDAS : Zero crossing and the heat equation. Rapport de Recherche, Courant institute of mathematical science, computer science division, 1984.
- [80] A. JAIN et F. FARROKHNI : Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, 24(12):1167–1186, 1991.
- [81] A. JAIN, S. PRABHAKAR, L. HONG et S. PANKANTI : Filterbank-based fingerprint matching. *IEEE Transactions on Image Processing*, 9(5):846–859, 2000.
- [82] S. JEHAN-BESSON : *Modles de contours actifs bass rgions pour la segmentation d'images et de videos*. Thèse de doctorat, Universit de Nice - Sophia Antipolis, janvier 2003.
- [83] L. JIANG et W. YANG : A modified fuzzy c-means algorithm for segmentation of magnetic resonance images. *Dans Digital Image Computing, Techniques and Applications*, pages 225–232, 2003.
- [84] J. JIMNEZ-ALANIZ, V. MEDINA-BAUELOS et O. YEZ-SUREZ : Data-driven brain MRI segmentation supported on edge confidence and a priori tissue infomation. *IEE Transactions on Medical Imaging*, 25(1):74–83, janvier 2006.
- [85] O. JUAN et R. KERIVEN : Trimap segmentation for fast and user-friendly alpha matting. *Dans Variational, Geometric, and Level Set Methods in Computer Vision*, pages 186–197, 2005.

- [86] O. JUAN, R. KERIVEN et G. POSTELNICU : Stochastic mean curvature motion in computer vision : stochastic active contours. *Dans 2nd IEEE Workshop on Variational, Geometric and Level Set Methods in Computer Vision*, October 2003.
- [87] M. KASS, A. WITKIN et D. TERZOPOULOS : Snakes : Active contour models. *International Journal of Computer Vision*, 1(4):321–331, 1987.
- [88] G. KELEMEN, G. SZKELY et G. GERIG : Elastic model-based segmentation of 3D neuroradiological data sets. *IEEE Transactions on Medical Imaging*, 18:828 – 839, octobre 1999.
- [89] Y. KESELMAN et E. MICHELI-TZANAKOU : Extraction and characterization of regions of interest in biomedical images. *Dans Information Technology Applications in Biomedicine, 1998. ITAB 98. Proceedings. 1998 IEEE International Conference on*, pages 87–90, 16-17 May 1998.
- [90] W. KHLER : *Psychologie de la forme*. Gallimard, 1929.
- [91] J. KLEMENCIC, J. PLUIM, M. VIERGEVER, H. SCHNACK et V. VALENCIC : Non-rigid registration based active appearance models for 3D medical image segmentation. *Journal of Imaging Science and Technology*, 48(2):166–171, 2004.
- [92] J. KOENDERINK : The structure of images. *Biological Cybernetics*, 50(5):363–370, août 1984.
- [93] J. KOENDERINK : Scale-time. *Biological Cybernetics*, 58(3):159–162, février 1988.
- [94] K. KOFFKA : *Principles of Gestalt Psychology*. Routledge & Kergan Paul, 1935.
- [95] V. KOLMOGOROV et R. ZABIN : What energy functions can be minimized via graph cuts? *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(2):147–159, février 2004.
- [96] F. LACHMANN : *Mthodes d'analyse d'images mdicales pour la reconnaissance de structures crbrales*. Thèse de doctorat, Universit Franois Rabelais - Tours, 1992.
- [97] Z. LAO, D. SHEN, A. JAWAD, B. KARACALI, D. LIU, E. MELHEM, R. BRYAN et C. DAVATZIKOS : Automated segmentation of white matter lesions in 3D brain MR images, using multivariate pattern classification. *Dans IEEE International Symposium on Biomedical Imaging : Macro to Nano*, pages 307–310, avril 2006.
- [98] Z. LAO, D. SHEN, Z. XUE, B. KARACALI, S. RESNICK et C. DAVATZIKOS : Morphological classification of brains via high-dimensional shape transformations and machine learning methods. *Neuroimage*, 21(1):46–57, janvier 2004.
- [99] F. LECELLIER, S. JEHAN-BESSON, M. FADILI, G. AUBERT et M. REVENU : Statistical region-based active contours with exponential family observations. *Dans International Conference on Acoustics, Speech and Signal Processing*, volume 2, pages 113–116, mai 2006.
- [100] F. LECELLIER, S. JEHAN-BESSON, M. FADILI, G. AUBERT, M. REVENU et E. SALOUX : Region-based active contours with noise and shape priors. *Dans International Conference on Image Processing*, pages 1649–1652, 2006.
- [101] C.-H. LEE, M. SCHMIDT, A. MURTHA, A. BISTRITZ, J. SANDER et R. GREINER : Segmenting brain tumors with conditional random fields and support vector machines. *Dans Computer Vision for Biomedical Imaging Applications*, pages 469–478, 2005.
- [102] K. Van LEEMPUT, F. MAES, D. VANDERMEULEN et P. SUETENS : Automatic segmentation of brain tissues and MR bias field correction using a digital brain atlas. *Dans International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 1222–1227, 1998.

- [103] F. LEITNER, I. MARQUE, S. LAVALLE et P. CINQUIN : *Dynamic segmentation : finding the edges with snakes splines*. Curves and Surfaces. Londres Academic Press, 1991.
- [104] D. LEMOINE, C. BARILLOT, B. GIBAUD et E. PASQUALINI : An anatomical-based 3D registration system of multimodality and atlas data in neurosurgery. *Dans Information Processing in Medical Imaging*, volume 511, pages 154–164, 1991.
- [105] H. LI, T. LIU, G. YOUNG, L. GUO et S. WONG : Brain tissue segmentation based on DWI/DTI data. *Dans International Symposium on Biomedical Imaging : Macro to Nano*, pages 57–60, avril 2006.
- [106] Z. LI : Pre-attentive segmentation in the primary visual cortex. *Spatial vision*, 13(1):25–50, 2000.
- [107] L. LIFSHITZ et S. PIZER : A multiresolution hierarchical approach to image segmentation based on intensity extrema. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(6):529–540, 1990.
- [108] T. LINDBERG : Scale-space for discrete signals. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(3):234–245, 1990.
- [109] T. LINDBERG : Detecting salient blob-like image structures and their scales with a scale-space primal sketch : A method for focus-of-attention. *International Journal of Computer Vision*, 11(3):283–318, 1993.
- [110] H. LOMBAERT, Y. SUN, L. GRADY et C. XU : A multilevel banded graph cuts method for fast image segmentation. *Dans International Conference on Computer Vision*, volume 1, pages 259–265, octobre 2005.
- [111] Y. MA et X. DING : Face detection based on hierarchical support vector machines. *Dans International Conference on Pattern Recognition*, volume 1, pages 222–225, 2002.
- [112] J. MACQUEEN : Some methods for classification and analysis of multivariate observations. *Dans Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, pages 281–297. University of California Press, 1967.
- [113] G. MALANDAIN, G. BERTRAND et N. AYACHE : Topological segmentation of discrete surfaces. *International Journal of Computer Vision*, 10(2):183–197, 1993.
- [114] S. MALLAT : A theory for multiresolution signal decomposition : The wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11:674–693, juillet 1989.
- [115] S. MALLAT : *A Wavelet Tour of Signal Processing*. Academic Press, 1998.
- [116] D. MARR : *Vision*. W.H.Freeman and Company, 1982.
- [117] D. MARR et E. HILDRETH : Theory of edge detection. *Proceedings of the Royal Society in Biological Sciences*, 207:187–217, 1980.
- [118] D. MARR et T. POGGIO : A computational theory of human stereo vision. *Proceedings of the Royal Society in Biological Sciences*, 204:301–328, 1979.
- [119] D. MARR, T. POGGIO et S. ULLMAN : Bandpass channels, zero-crossings, and early visual information processing. *Journal of the Optical Society of America*, 69:914–916, 1979.
- [120] G. MATHERON : *Random Sets and integral geometry*. John Wiley & Sons Inc, 1975.
- [121] A. MAYER et H. GREENSPAN : Segmentation of brain MRI by adaptive mean shift. *Dans International Symposium on Biomedical Imaging : Macro to Nano*, pages 319–322, avril 2006.

- [122] S. MENET, P. SAINT MARC et G. MEDIONI : B-snakes : Implementation and application to stereo. *Dans Image Understanding Workshop*, pages 720–726, 1990.
- [123] F. MEYER : Skeletons in digital spaces. *Image Analysis and Mathematical Morphology*, 2:257–296, 1988.
- [124] O. MONGA, N. AYACHE et P. SANDER : Using uncertainty to link 3d edge detection and local surface modelling. *Dans International Conference on Information Processing in Medical Imaging*, pages 273–284. Springer-Verlag, 1991.
- [125] O. MONGA, N. AYACHE et P. SANDER : From voxels to curvature features. *Dans International workshop on Visual form : analysis and recognition*, pages 399–407. Plenum Press, 1992.
- [126] O. MONGA et S. BENAYOUN : Using partial derivatives of 3d images to extract typical surface features. *Computer Vision and Image Understanding*, 61(2):171–189, 1995.
- [127] O. MONGA, R. DERICHE, G. MALANDAIN et J.P. COCQUEREZ : Recursive filtering and edge closing : two primary tools for 3-d edge detection. *Dans European Conference on Computer Vision*, pages 56–65. Springer-Verlag, 1990.
- [128] O. MONGA, R. DERICHE et J.-M. ROCCHISANI : 3d edge detection using recursive filtering : application to scanner images. *Computer Vision, Graphics and Image Processing : Image Understanding*, 53(1):76–87, 1991.
- [129] D. NAIN, S. HAKER, A. BOBICK et A. TANNENBAUM : Multiscale 3-d shape representation and segmentation using spherical wavelets. *IEEE Transactions on Medical Imaging*, 26(4):598–618, avril 2007.
- [130] N. NEYKOV, P. FILZMOSER, R. DIMOVA et P. NEYTCHEV : Mixture of GLMs and the trimmed likelihood methodology. *Dans Computational Statistics*, 2004.
- [131] S. OSHER et J. SETHIAN : Fronts propagating with curvature-dependent speed : Algorithms based on Hamilton-Jacobi formulations. *Journal of Computational Physics*, 79:12–49, 1988.
- [132] N. PARAGIOS et R. DERICHE : A PDE-based level-set approach for detection and tracking of moving objects. *Dans International Conference on Computer Vision*, pages 1139–1145, janvier 1998.
- [133] S. PENG et L. GU : A novel implementation of watershed transform using multi-degree immersion simulation. *Dans International Conference of the Engineering in Medicine and Biology Society*, pages 1754–1757, septembre 2005.
- [134] D. PHAM : Robust fuzzy segmentation of magnetic resonance images. *Dans Symposium on Computer-Based Medical Systems*, pages 127–131, juillet 2001.
- [135] D. PHAM et J. PRINCE : An adaptive fuzzy c-means algorithm for image segmentation in the presence of intensity inhomogeneities. *Pattern Recognition Letters*, 20(1):57–68, janvier 1999.
- [136] D. PHAM et J. PRINCE : Adaptive fuzzy segmentation of magnetic resonance images. *IEEE Transactions on Medical Imaging*, 18(9):737–752, septembre 1999.
- [137] S. PRABHAKAR : *Fingerprint Classification and Matching Using a Filterbank*. Thèse de doctorat, Michigan State University, 2001.
- [138] V. PRINET et T. BAILLOEUL : Active contours with spatio-temporal shape prior constraint. *Dans Mathematical Model for Multi-Channel Image Processing*, 2006.
- [139] A. QUDDUS, P. FIEGUTH et O. BASIR : Adaboost and support vector machines for white matter lesion segmentation in MR images. *Dans International Conference of the Engineering in Medicine and Biology Society*, pages 463–466, septembre 2005.

- [140] M. RAHMAN, W. CHAI et A. ABDESSEALM : Scale-space characteristics for image segmentation. *Dans International Conference on Electrical and Electronic Technology*, volume 1, pages 28–32, août 2001.
- [141] S. RITAL, H. CHERIFI et S. MIGUET : K-way hypergraph partitioning and color image segmentation. *Dans International Symposium on Communications, Control and Signal Processing*, march 2006.
- [142] S. RITAL, H. CHERIFI et Miguet S. : A segmentation algorithm for noisy images. *Dans International Conference on Computer Analysis of Images and Patterns*, volume 3691, pages 205–212, septembre 2005.
- [143] S. RITAL, H. CHERIFI et Miguet S. : Weighted adaptive neighborhood hypergraph partitioning for image segmentation. *Dans International Conference on Advances in Pattern Recognition*, volume 3687, pages 522–531, août 2005.
- [144] J. ROERDINK et A. MEIJSTER : The watershed transform : Definitions, algorithms and parallelization strategies. *Fundamenta Informaticae*, 41(1-2):187–228, 2000.
- [145] C. ROTHER, V. KOLMOGOROV et A. BLAKE : "grabcut" : interactive foreground extraction using iterated graph cuts. *Dans Special Interest Group on Graphics and Interactive Techniques*, pages 309–314, 2004.
- [146] M. ROUSSON, N. PARAGIOS et R. DERICHE : Active shape models from a level set perspective. Rapport de Recherche 4984, Inria, 2003.
- [147] M. ROUSSON, N. PARAGIOS et R. DERICHE : Implicit active shape models for 3d segmentation in MR imaging. *Dans Medical Image Computing and Computer-Assisted Intervention*, volume 3216 de *Lecture Notes in Computer Science*, pages 209–216. Springer Berlin / Heidelberg, 2004.
- [148] S. ROY et I. COX : A maximum-flow formulation of the camera stereo correspondence problem. *Dans International Conference on Computer Vision*, pages 492–499, 1998.
- [149] S. RUAN, D. BLOYET, M. REVENU, W. DOU et Q. LIAO : Cerebral magnetic resonance image segmentation using fuzzy markov random fields. *Dans International Symposium on Biomedical Imaging*, pages 237–240, juillet 2002.
- [150] F. SALZENSTEIN et W. PIECZYNSKI : Parameter estimation in hidden fuzzy markov random fields and image segmentation. *Graphical Models and Image Processing*, 59(4):205–220, 1997.
- [151] R. SAMMOUDA, N. NIKI et H. NISHITANI : A comparison of Hopfield neural network and Boltzmann machine in segmenting MR images of the brain. *IEEE Transactions on Nuclear Science*, 43(6):3361–3369, décembre 1996.
- [152] J. SERRA : *Image Analysis and Mathematical Morphology*. Academic Press, 1982.
- [153] J. SETHIAN : *Level set methods and fast marching methods. Evolving interfaces in computational geometry, fluid mechanics, computer vision and material science*. Cambridge University Press, 1999.
- [154] F. SGONNE, A. DALE, E. BUSA, M. GLESSNER, D. SALAT, H. HAHN et B. FISCHL : A hybrid approach to the skull stripping problem in MRI. *NeuroImage*, 22(3):1060–1075, 2004.
- [155] D. SHEN, E. HERSKOVITS et C. DAVATZIKOS : An adaptive-focus statistical shape model for segmentation and shape modeling of 3-D brain structures. *IEEE Transactions on Medical Imaging*, 20(4):257–270, avril 2001.

- [156] J. SHEN et S. CASTAN : An optimal linear operator for edge detection. *Dans International Conference on Vision and Pattern Recognition*, pages 109–114, 1986.
- [157] P. SHIH et C. LIU : Face detection using discriminating feature analysis and support vector machine. *Pattern Recognition*, 39(2):260–276, 2006.
- [158] P. SIMPSON : *Artificial neural systems : foundations, paradigms, applications, and implementations*. Pergamon Press, 1990.
- [159] I. SOBEL et G. FELDMAN : A 3x3 isotropic gradient operator for image processing. Never published but presented at a talk at the Stanford Artificial Project, 1968.
- [160] Z. SONG, N. TUSTISON, B. AVANTS et J. GEE : adaptative graph cuts with tissue priors for brain MRI segmentation. *Dans International Symposium Biomedical Imaging*, pages 762–765, 2006.
- [161] J. TALAIRACH, G. SIZKLA, P. TOURNOUX, A. PROSALENTIS et M. BORNAS-FERRIER : *Atlas d'anatomie strotaxique de tlencphale*. Masson & Cie, 1967.
- [162] J. TALAIRACH et P. TOURNOUX : *Co-planar Stereotaxic Atlas of the Human Brain*. Georg Thieme Verlag, 1988.
- [163] C. TAN et J. RAJAPAKSE : Tissue segmentation of multi-channel brain images with inhomogeneity correction. *Dans International Symposium on Image and Signal Processing and Analysis*, volume 1, pages 571–576, septembre 2003.
- [164] J. THIRAN, V. WARSCOTTE et B. MACQ : A queue-based region growing algorithm for accurate segmentation of multi-dimensional digital images. *Signal Processing*, 60(1):1–10, 1997.
- [165] A. TIKHONOV : Solution of incorrectly formulated problems and the regularization method. *Soviet mathematics Doklady*, 4:1035–1038, 1963.
- [166] A. TIKHONOV et V. ARSEININ : *Solution of Ill-posed Problems*. Winston & Sons, 1977.
- [167] A. TSAI, A. YEZZI, W. WELLS, C. TEMPANY, D. TUCKER, A. FAN, W. GRIMSON et A. WILLISKY : A shape-based approach to the segmentation of medical imagery using level sets. *IEEE Transactions on Medical Imaging*, 22(2):137–154, février 2003.
- [168] C. VACHIER, S. MULLER et S. BOTHOREL : Analyse morphologique des clichés mammographiques en vue de la dtecton des opacités du sein. *Dans Proceedings of ADEBIO*, 1997.
- [169] V. VAPNIK : *The nature of statistical learning theory*. Springer-Verlag New York, Inc., 1995.
- [170] B. VEMURI, S. RAHMAN et J. LI : Multiresolution adaptive K-means algorithm for segmentation of brain MRI. *Dans International Computer Science Conference on Image Analysis Applications and Computer Graphics*, pages 347–354, 1995.
- [171] L. VINCENT et P. SOILLE : Watershed in digital spaces, an efficient algorithm based on immersion simulation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(6):583–598, juin 1991.
- [172] Y. WELDESELASSIE et G. HARMANEH : DT-MRI segmentation using graph cuts. *Dans SPIE Conference on Medical Imaging : Image Processing*, volume 6512, 2007.
- [173] A. WITKIN : Scale-space filtering. *Dans International Joint Conference on Artificial Intelligence*, pages 1019–1022, 1983.
- [174] A. WITKIN : Scale-space filtering : A new approach to multi-scale description. *Dans IEEE International Conference on Acoustic, Speech and Signal Processing*, volume 9, pages 150–153, mars 1984.

-
- [175] J. WU et A. CHUNG : Multimodal brain image registration based on wavelet transform using SAD and MI. *Dans Medical Imaging and Augmented Reality*, pages 270–277, 2004.
- [176] C. XU et J. PRINCE : Gradient vector flow : a new external force for snakes. *Dans International Conference on Computer Vision and Pattern Recognition*, pages 66–71, juin 1997.
- [177] C. XU et J. PRINCE : Snakes, shapes, and gradient vector flow. *IEEE Transactions on Image Processing*, 7(3):359–369, mars 1998.
- [178] N. XU, R. BANSAL et N. AHUJA : Object segmentation using graph cuts based active contours. *Computer Vision and Pattern Recognition*, 2:46, 2003.
- [179] J. XUE, S. RUAN, B. MORETTI, M. REVENU et D. BLOYET : Knowledge-based segmentation and labeling of brain structures from MRI images. *Pattern Recognition Letters*, 22(3-4):395–405, 2001.
- [180] J. XUE, S. RUAN, B. MORETTI, M. REVENU, D. BLOYET et W. PHILIPS : Fuzzy modeling of knowledge for MRI brain structure segmentation. *Dans International Conference on Image Processing*, volume 1, pages 617–620, 2000.
- [181] M. YAN et J. KARP : Segmentation of 3D brain MR using an adaptive K-means clustering algorithm. *Dans Nuclear Science Symposium and Medical Imaging Conference*, pages 1529–1533, 1995.
- [182] R. ZABIH et V. KOLMOGOROV : Spatially coherent clustering using graph cuts. *Dans International Conference on Computer Vision and Pattern Recognition*, volume 2, pages 437–444, juillet 2004.
- [183] L. ZAGORCHEV, A. GOSHTASBY et M. SATTER : R-snakes. *Image and Vision Computing*, 25(6):945–959, 2007.
- [184] Z. ZHOU et Z. RUAN : Brain magnetic resonance images segmentation based on wavelet method. *Dans International Conference of the Engineering in Medicine and Biology Society*, 2005.
- [185] Z. ZHOU et Z. RUAN : Multicontext wavelet-based thresholding segmentation of brain tissues in magnetic resonance images. *Magnetic Resonance Imaging*, 25(3):381–385, juin 2007.
- [186] S. ZUCKER : Region growing : Childhood and adolescence. *Computer Graphics, Image Processing*, 5(3):382–399, septembre 1976.



Unité de recherche INRIA Rennes
IRISA, Campus universitaire de Beaulieu - 35042 Rennes Cedex (France)

Unité de recherche INRIA Futurs : Parc Club Orsay Université - ZAC des Vignes
4, rue Jacques Monod - 91893 ORSAY Cedex (France)

Unité de recherche INRIA Lorraine : LORIA, Technopôle de Nancy-Brabois - Campus scientifique
615, rue du Jardin Botanique - BP 101 - 54602 Villers-lès-Nancy Cedex (France)

Unité de recherche INRIA Rhône-Alpes : 655, avenue de l'Europe - 38334 Montbonnot Saint-Ismier (France)

Unité de recherche INRIA Rocquencourt : Domaine de Voluceau - Rocquencourt - BP 105 - 78153 Le Chesnay Cedex (France)

Unité de recherche INRIA Sophia Antipolis : 2004, route des Lucioles - BP 93 - 06902 Sophia Antipolis Cedex (France)

Éditeur
INRIA - Domaine de Voluceau - Rocquencourt, BP 105 - 78153 Le Chesnay Cedex (France)
<http://www.inria.fr>
ISSN 0249-6399