

2m11,2744.6

11309699

Université de Montréal

Classification d'images SPECT du cerveau basée sur une analyse
de la texture

par

Yasmina Chaïbi

Département d'informatique et de recherche opérationnelle
Faculté des arts et des sciences

Mémoire présenté à la Faculté des études supérieures
en vue de l'obtention du grade de
Maître ès sciences (M.Sc.) en Informatique

20 décembre 1999

© Yasmina CHAIBI, 1999



CPA

76

USA

2000

M.003

Classification de sécurité

Classification de sécurité de l'information basée sur une
évaluation de la menace

100

Classification de sécurité

Classification de sécurité de l'information basée sur une
évaluation de la menace

Classification de sécurité de l'information basée sur une
évaluation de la menace

Classification de sécurité

Classification de sécurité



Université de Montréal
Faculté des études supérieures
Ce mémoire intitulé

Classification d'images SPECT du cerveau basée sur une analyse
de la texture

présenté par :

Yasmina Chaïbi

a été évalué par un jury composé des personnes suivantes :

(président-rapporteur)

Pierre Poulin

(directeur de recherche)

Jean Meunier

(membre du jury)

Yoshua Bengio

Mémoire accepté le :

20 décembre 1999

À mes parents et à ma petite sœur.

Sommaire

L'imagerie par SPECT (tomographie par émission de photon unique contrôlée par ordinateur) est une technique complexe dans son principe, mais riche dans la diversité des informations qu'elle peut fournir. Elle peut non seulement décrire efficacement en 3D des lésions d'organes, mais aussi aider à l'examen de structures plus complexes. Pour toutes ces raisons, l'imagerie par SPECT est aujourd'hui très utilisée en médecine nucléaire.

Ce mémoire analyse des images SPECT 3D de différents types de cerveaux, selon une technique basée sur la texture. Notre projet se divise en quatre étapes: (1) Les images SPECT étant de type aléatoire et les cerveaux étant constitués de tissus mous, une méthode d'analyse statistique a été utilisée: la méthode des matrices de cooccurrences (MC), d'implantation facile, où les valeurs de la matrice résument la dépendance des niveaux de gris d'une image. Nous avons extrait une série d'attributs de chaque matrice, afin de caractériser deux types d'images 3D de cerveaux: (a) cerveaux à maladie focale (CF); (b) cerveaux à maladie diffuse (CD). (2) Nous avons développé deux nouvelles techniques de calcul des matrices de cooccurrences, mieux adaptées aux images 3D de cerveaux: l'une, basée sur le calcul du plan mi-sagittal du cerveau à l'aide du critère de changement de signe stochastique (SSC), et où le calcul des MC est effectué par symétrie; l'autre, basée sur le calcul d'une image miroir de l'image originale, et où le calcul des MC est effectué à l'aide des deux images recalées. Ces deux techniques permettent de calculer des MC, capturant des informations

plus pertinentes sur la texture des images. (3) Nous avons aussi proposé une nouvelle méthode de calcul des attributs de la texture à partir des MC, basée sur l'analyse en composantes principales, le but étant de déterminer un nombre plus limité d'attributs qui caractériseraient tout aussi efficacement les textures des cerveaux. (4) Nous avons utilisé le classificateur de Bayes et la validation croisée afin de classifier les trois catégories de cerveaux en utilisant les différentes approches de calcul des MC et des attributs décrites plus haut.

Les résultats obtenus à l'aide de ces différentes techniques se sont révélés encourageants: pour les deux catégories d'images définies plus haut, nos méthodes fonctionnent nettement mieux que celle proposée par Haralick. En effet, la méthode proposée par Haralick nous a permis d'obtenir un taux de réussite égal à 53.58%, soit une erreur de généralisation $R(f) < 99.09\%$ avec une confiance $> 90\%$; tandis que notre méthode — basée sur le calcul des MC par symétrie tout en utilisant la méthode d'analyse par composantes principales pour le calcul des attributs de la texture — nous a permis d'obtenir un taux de classification correct sur notre ensemble de test égal à 100%, soit une erreur de généralisation $R(f) < 20\%$ avec une confiance $> 90\%$. Nous espérons que ces travaux aideront dans le futur à réduire la charge de travail du médecin en permettant de faire une classification préliminaire des images SPECT du cerveau.

Table des matières

Sommaire	i
Table des figures	vi
Liste des tableaux	viii
Remerciements	ix
1 Introduction	1
2 L'imagerie par SPECT	4
2.1 Historique	4
2.2 Les principes physiques de l'imagerie SPECT	8
2.2.1 La désintégration radioactive	8
2.2.2 Le traceur radioactif	8
2.2.3 Mesure de radiation	9
2.2.4 Le détecteur de radiation en SPECT et imagerie tomographique .	11
2.3 Avantages de l'imagerie SPECT	13
2.4 Inconvénients de l'imagerie SPECT	14
3 L'analyse des textures	16
3.1 Définition de la texture	17
3.2 Les étapes d'analyse des textures	20
4 Les attributs de la texture	25
4.1 Méthodes statistiques	26
4.1.1 Les moments statistiques	27
4.1.2 Les matrices de cooccurrences	28

4.1.3	Les différences de niveaux de gris	34
4.1.4	Les matrices de longueurs de plages	36
4.2	Méthodes spectrales ou d'analyse fréquentielle	39
4.2.1	L'énergie des textures par la transformée de Fourier	40
4.2.2	La méthode des filtres de Gabor	43
4.2.3	La transformée en ondelettes	44
4.3	L'approche basée sur la modélisation des textures	45
4.4	Méthodes structurelles	51
4.5	Méthodes fractales	51
4.5.1	La dimension fractale (DF)	52
4.5.2	Les approches utilisées pour estimer la DF d'une image	53
5	Les méthodes de classification	59
5.1	Introduction	59
5.2	Les méthodes basées sur la théorie de la décision	60
5.2.1	Les méthodes statistiques	60
5.2.2	Les réseaux de neurones	68
5.3	Les méthodes de classification structurelles	73
6	Méthodes et résultats	77
6.1	Données et problématique	77
6.2	Étapes préliminaires	79
6.2.1	Choix du modèle	79
6.2.2	Prétraitement	81
6.2.3	Validation	82
6.3	Les méthodes	83
6.3.1	Méthode (1a)	85
6.3.2	Méthode (1b)	88
6.3.3	Méthode (1c)	93
6.3.4	Méthode (2a)	96
6.3.5	Méthode (2b)	101
6.4	Conclusion	102
7	Discussion et conclusion	105

Références**110**

Table des figures

2.1	Scanner de Cassen et caméra Anger	6
2.2	Détecteur de scintillations et les différentes interactions des rayons gamma	10
2.3	Appareillage du système SPECT	11
2.4	Représentations 2D de vingt-et-une tranches transverses d'un cerveau .	12
3.1	Exemples de textures	16
3.2	Diagramme des étapes de classification des textures	21
4.1	Partitionnement radial et angulaire de l'espace de la transformée de Fourier	41
4.2	Les structures du système de voisinage	47
4.3	Les types de cliques associés aux systèmes de voisinages η^1 et η^2	48
4.4	Détermination de n_r par la méthode des boîtes	56
5.1	Image de gauche: Image originale. Image de centre: Image à ajuster. Image de droite: Résultat de la corrélation entre une l'image originale et l'image à ajuster dans le domaine des fréquences	65
5.2	Architecture d'un modèle de perceptron pour deux classes d'attributs .	69
5.3	Structure d'un réseau de neurones à multicouches	71
5.4	Texture composée de primitives en formes de cercles arrangées de façon à former une matrice 3×3	74
6.1	Image 2D d'un cerveau à maladie focale	78
6.2	Image 2D de cerveau à maladie diffuse	79
6.3	Image 2D quantifiée à partir d'une image de cerveau à maladie diffuse (fig. 6.2)	82
6.4	Illustration graphique des six voisins d'un pixel quelconque d'une image 3D utilisés pour le calcul d'une matrice de cooccurrences de distance interpixel égale à d	86

6.5	Illustration d'une matrice de cooccurrences calculée à partir d'un cerveau à maladie diffuse en utilisant la méthode (1a)	87
6.6	Illustration d'une matrice de cooccurrences calculée à partir d'un cerveau à maladie diffuse en utilisant la symétrie	89
6.7	Illustration d'une matrice de cooccurrences calculée à partir d'un cerveau à maladie focale en utilisant la symétrie	89
6.8	Transformation linéaire maximisant le critère du changement de signes stochastique (SSC) pour une image d'ellipse et son image miroir	92
6.9	Formation d'un vecteur d'attributs à partir des valeurs appartenant à 13 matrices de cooccurrences	97
6.10	Illustration graphique des valeurs propres de la matrice de covariance calculée à partir des matrices de cooccurrences des CF	99
6.11	Illustration des quatre premières composantes principales calculées à partir des matrices de cooccurrences des cerveaux à maladie focale . . .	100

Liste des tableaux

6.1	Résultats de la classification des CD et des CF en utilisant les attributs et les matrices de cooccurrences proposés par Haralick	88
6.2	Résultats de la classification des CD et des CF en utilisant les attributs proposés par Haralick et le critère SSC	93
6.3	Résultats de la classification des CD et des CF en utilisant les attributs proposés par Haralick et les matrices de cooccurrences calculées à l'aide du logiciel SPM	95
6.4	Les valeurs propres de la matrice de covariance calculée à partir des matrices de cooccurrences des CF	99
6.5	Résultats de la classification des CD et des CF en utilisant les matrices de cooccurrences proposées par Haralick et l'ACP pour le calcul des attributs de la texture	101
6.6	Résultats de la classification des CD et des CF en utilisant les matrices de cooccurrences calculées à l'aide du logiciel SPM et l'analyse en composantes principales pour le calcul des attributs de texture	102
6.7	Risques empiriques minimaux correspondants à des combinaisons d'attributs appliquées à chaque type de méthode	102
6.8	Bornes inférieures des risques espérés correspondants à des combinaisons d'attributs appliquées à chaque type de méthode	104

Remerciements

Inscrire son nom sur un mémoire achevé c'est non seulement le résultat d'un long et laborieux travail de recherches et d'études mais aussi une fierté que je voudrais partager avec toutes les personnes qui ont contribuées par leur support moral et technique à l'élaboration de ce mémoire.

Tout d'abord je voudrais remercier mon directeur de recherche Monsieur Jean Meunier. L'espace réservé aux remerciements ne sera jamais assez suffisant pour me permettre d'exprimer toute ma gratitude envers lui. Je tiens à le remercier tout d'abord de m'avoir accueilli au sein de son laboratoire, pour son temps précieux qu'il a bien voulu me consacrer, sa disponibilité, sa bonne humeur en tout temps, ses encouragements perpétuels et son aide bénéfique. Bref, pour son professionnalisme et sa chaleur humaine.

Je tiens à remercier également mon codirecteur de recherche le Docteur Jean-Paul Soucy du département de médecine nucléaire de l'hôpital Notre-Dame. Je lui suis reconnaissante pour sa disponibilité et le temps qu'il m'a consacré à rechercher et visualiser les images SPECT nécessaires à la réalisation de ce mémoire. Aussi, je remercie tous les membres du département de médecine nucléaire qui ont eu la bonté — bien que très occupés — de «supporter» ma présence et m'aider dans mon travail dans ces lieux.

Je remercie également les membres de mon jury pour leurs corrections, conseils et commentaires très utiles.

Un gros merci à ma très chère maman, qui m'a apporté son aide de professionnelle en la matière et a suivi de près la rédaction du premier chapitre de ce mémoire, celui consacré à la physique nucléaire et à l'imagerie SPECT.

Un autre gros merci à mon cher papa, qui a su passer avec son œil de lynx à travers mon mémoire et corriger toutes, ou presque, mes fautes de frappes.

Aussi, je tiens à remercier tous les membres du laboratoire de vision et de modélisation géométrique et en particulier Sébastien Roy pour son amitié, sa bonne humeur et son aide, Bernard Imbert pour son humour et sa chaleur méditerranéenne et Max Mignotte qui m'a apporté son aide inestimable en \LaTeX et a su régler les problèmes de compilation de ce langage même quand cela lui paraissait «très bizarre».

Je voudrais également remercier tous ceux et celles qui ont su me «débrancher» quand il le fallait, m'encourager et me pousser vers l'avant. Je cite ma petite sœur Nadia et mes amis: Lilia Mokri, les Bourennani, les Kerdel, Amel Fortas, Normand et Monique Lapointe et Nicolas Chapados. Aussi, je tiens à remercier mes grands-parents et tous mes amis d'outremer qui n'ayant pas pu être ici ont su m'apporter leur aide morale et leurs encouragements les plus chaleureux. Je cite: Julia Kurtsman, Éléna Neroslavskaya, Walid Khoury, Rachid Malti, Henry Rodrigèz, Vera Akimova et beaucoup d'autres.

Pour finir, je tiens à remercier la personne qui a su être la plus patiente et la plus présente tout au long de ce long processus de recherche et de rédaction. Je remercie Jean-François pour sa compréhension, ses encouragements continus et son écoute. Je le remercie de m'avoir initié à \LaTeX et de m'avoir aidé à l'utiliser, je lui suis reconnaissante pour le temps qu'il a pris pour lire mon mémoire, le corriger et me donner ses commentaires. Jean-François, merci pour tout!

Chapitre 1

Introduction

Depuis toujours, l'homme s'intéresse à la façon de mieux représenter le corps humain, afin de pouvoir mieux l'étudier et le comprendre. Déjà, dans l'antiquité, les maîtres de la sculpture antique tentaient de représenter le corps humain sous sa forme la plus parfaite. Les grands peintres, quant à eux, essayèrent, à travers leurs œuvres, de reproduire le corps humain de façon plus réaliste : de la Renaissance, par exemple, nous sont parvenus les croquis anatomiques de Leonard De Vinci. Ces études et représentations n'étaient cependant exécutées qu'à partir de corps inertes et disséqués. Mais, visant toujours plus haut, l'homme voulut concevoir des techniques qui lui permettraient de visualiser les organes internes de corps vivants, afin de comprendre leur fonctionnement *in vivo*.

Les technologies évoluèrent, et l'homme adapta ses exigences à elles. Ainsi, au XIX^e siècle, le monde de la médecine fut révolutionné par l'apparition des premières images par rayons X. Enfin les médecins avaient à leur disposition des instruments capables de fournir des images anatomiques provenant de corps vivants! Depuis, plusieurs méthodes de visualisation, dont l'imagerie par émission de photon unique contrôlée par ordinateur (SPECT), ont été développées. L'imagerie SPECT, bien que fort complexe, est à l'heure actuelle la méthode par excellence en médecine nucléaire pour l'acquisition d'images. Le chapitre 2 de notre mémoire est entièrement consacré à

l'imagerie SPECT. Nous y verrons les grandes lignes de cette technique : ses principes physiques, ses points forts, de même que ses inconvénients.

Au delà de la seule imagerie médicale, l'objectif principal de ce mémoire est de développer des techniques capables d'aider le médecin durant son diagnostic, ou, plus précisément, de pouvoir automatiser certaines parties de ce processus, par le biais de l'analyse de texture. Notre but est de développer une méthode efficace d'analyse de texture plus adaptée au dépistage de deux types de maladie touchant spécifiquement les cerveaux. Ainsi donc, le chapitre 3 traite de l'analyse de texture. Aucune définition unique satisfaisante de la texture n'a pu être formulée par les chercheurs ; la première partie du chapitre est donc consacrée à regrouper les différentes définitions de la texture apparaissant dans la littérature. Par la suite, nous décrivons les différentes étapes d'analyse de texture : 1° l'acquisition des images, 2° le prétraitement, 3° l'acquisition des attributs de la texture, 4° l'estimation des paramètres du classificateur ainsi que 5° la classification.

Le chapitre 4 est consacré à la troisième étape d'analyse de texture. Nous effectuons tout d'abord une revue bibliographique des différentes méthodes utilisées à cet effet : 1° statistique, 2° structurelle, 3° spectrale, 4° fractale et 5° celle basée sur la modélisation des textures. Étant donné que les images médicales SPECT sont des images du type aléatoire et que les méthodes statistiques sont fortement recommandées pour traiter ce type d'images, un accent spécial sera porté sur les méthodes d'analyse statistique.

Le chapitre 5 est consacré aux deux dernières étapes d'analyse de texture. Nous effectuons tout d'abord une revue de littérature des différentes méthodes de classification : 1° celles basées sur les théories de la décision — méthodes statistiques et réseaux de neurones — et 2° les méthodes de classifications structurelles. Ici aussi, l'accent portera surtout sur les méthodes statistiques de classification.

Pour terminer, le chapitre 6 est consacré à la description des cinq méthodes que nous avons utilisées afin d'analyser des images médicales SPECT selon une approche

statistique de l'analyse de texture. Plus précisément, nous proposerons deux catégories d'attributs: l'une, inspirée de celle proposée par HARALICK, SHANMUGAM et DINSTEIN (1973) et l'autre, basée sur l'analyse en composantes principales. Pour chacune d'elles, nous proposons également trois façons de calculer les matrices de co-occurrence. Nous verrons en détail les améliorations que nous avons apportées aux méthodes déjà existantes, de même que les résultats de classifications obtenus par chacune des approches.

Chapitre 2

L'imagerie par SPECT

De nos jours, les hôpitaux sont la seconde plus importante source d'images numériques dans le monde et ce, après les satellites. En moyenne, un hôpital génère chaque année 500,000 images. De l'ensemble des ressources humaines et technologiques développées dans le domaine médical, une proportion considérable est allouée à l'obtention d'images médicales propres à assister le processus du diagnostic. L'utilisation des ordinateurs dans le contexte clinique joue un rôle à plusieurs niveaux :

- L'acquisition d'images.
- L'affichage des images acquises afin qu'elles soient interprétées par le clinicien.
- Le traitement d'images numériques enregistrées en clinique.
- Le contrôle des systèmes d'imagerie.

2.1 Historique

C'est à la toute fin du XIX^e siècle, soit en 1895, que Röntgen découvrit les rayons X. Ceux-ci sont émis à partir de tubes à vide, et proviennent des surfaces qui reçoivent le bombardement cathodique. Ce sont des radiations électromagnétiques de même nature que la lumière mais d'une longueur d'onde beaucoup plus courte. L'utilité des

rayons X en médecine ne fut cependant découverte qu'en 1915 par le médecin français Boccage, donnant ainsi naissance à la tomographie optique¹. Les tomographies sont alors obtenues en faisant subir au tube générateur de rayons X et au film sensible des mouvements de déplacement par rapport à l'organe à radiographier, de telle façon à ce que les images contenues dans un plan privilégié (où se situe l'axe de ce déplacement) demeurent seules lisibles (LAROUSSE 1981). Il a fallu quand même vingt années supplémentaires pour que la tomographie planaire devienne l'une des techniques principales utilisées en radiologie.

Notons que la tomographie planaire comporte plusieurs imperfections: tout d'abord, il est impossible d'éviter que les structures existantes à l'extérieur du plan n'apparaissent sur les radiographies; ensuite cette technique produit des images à faible contraste; finalement, la radiation reçue par le patient est non négligeable (CROFT 1986).

La différence majeure entre la radiologie par rayons X et la médecine nucléaire est que cette dernière exploite les différences dans la distribution d'un traceur radioactif administré dans le corps du patient, tandis que la première exploite les différences des rayons X atténués dans les tissus des organes après avoir été envoyés vers eux par une source extérieure.

Le premier système d'imagerie par rayons gamma fut développé par Cassen entre les années 1940 et 1950 (voir le schéma 2.1.A). Le système en question était un scanner mécanique constitué d'un détecteur de scintillations et capable de se déplacer en mouvements rectilignes au-dessus du patient. Les intensités des rayons gamma détectées étaient alors représentées comme une fonction de la position du scanner, afin de générer une image représentative de la distribution du traceur. Mais, l'invention par Anger, en 1957, de la caméra à scintillations (voir le schéma 2.1.B) devait changer le cours de la médecine nucléaire. À la différence du scanner de Cassen, la caméra An-

1. La tomographie optique ou non numérique (c'est-à-dire non assistée par ordinateur) est un procédé de radiographie qui permet d'obtenir une image nette d'un seul plan de coupe d'organe, avec effacement des autres plans (LAROUSSE 1981).

ger était constituée d'un détecteur de scintillations stationnaire, formé d'un cristal à large diamètre comprenant une matrice de tubes photomultiplicateurs, ce qui permit d'obtenir une vue globale de l'organe (JASZCZAK, COLEMAN et LIM 1980).




FIG. 2.1 – (A) Scanner de Cassen, (B) Caméra Anger—Tirées de (Jaszczak, Coleman et Lim 1980)

Bien que la caméra Anger permettait d'obtenir de grandes images, son utilisation réelle en médecine nucléaire fut tardive, et ce, à cause de son fonctionnement complexe.

Vers 1958, Khul remarqua qu'il pouvait tirer parti du scanner à collimateur focalisé s'il faisait «tourner» ce dernier autour de l'organe. Il pouvait ainsi apercevoir les gros organes (le foie, par exemple) sous tous leurs angles. En 1963, Kuhl et Edwards proposèrent d'utiliser le scanner focalisé en tomographie. Ceci fut possible en plaçant l'instrument sur un support mécanique à déplacement complexe permettant de faire des rotations et d'ajouter à cet appareillage un oscilloscope. L'année suivante, ils purent ainsi élaborer le balayage² stéréoscopique, longitudinal et transversal. Grâce à eux, à partir de ce moment, la tomographie par émission devient l'un des outils les plus importants en diagnostic médical.

2. scanning

En 1968, Khul et Edwards suggérèrent l'utilisation de l'ordinateur numérique à des fins d'acquisition et d'enregistrement des données obtenues par leurs instruments. L'ordinateur devient alors l'outil par excellence en tomographie par émission, mais uniquement comme outil de stockage et de rehaussement de contraste. À la même époque, Cormack proposa l'utilisation des mathématiques afin de synthétiser une image transaxiale à partir d'images projetées.

En 1973, Hounsfield utilisa pour la première fois la tomographie par rayons X assistée par ordinateur pour prendre des images de la tête. L'année d'après, Ledley et ses associés firent de même avec le *X-ray ACTA scanner* obtenant ainsi d'impressionnantes images couleurs. La même année, Budinger et Gullberg firent une excellente revue des différents développements théoriques touchant la reconstruction et discutèrent des applications possibles de chaque théorie à la médecine nucléaire. Tandis que la transmission tomographique par rayons X assistée par ordinateur devenait un succès mondial, le chemin s'ouvrait à de nouvelles inventions en médecine nucléaire. Ceci commença par l'installation d'une unité tomographique en 1971 à l'hôpital Alkinson Morley en Angleterre. Au cours des années suivantes, le développement de la caméra Anger rotatoire et des équipements informatiques a permis à la tomographie par émission de photon unique contrôlée par ordinateur (SPECT³) de devenir une réalité.

Aujourd'hui, l'utilisation de systèmes multicristaux à colimateur focalisé SPECT⁴, le descendant de l'instrument original de Kuhl, de même que du plus récent *single-photon ring tomograph* (SPRINT) sont chose courante dans les hôpitaux. L'utilisation croissante du SPECT est due à sa capacité de localiser et d'étudier les structures d'organes en fonction de leurs propriétés physiques et biochimiques (CROFT 1986).

3. *Single Photon Emission Computed Tomography*

4. *Multicrystal Focused Collimator SPECT systems*

2.2 Les principes physiques de l'imagerie SPECT

Il existe plus de cent éléments atomiques, chacun formé d'un noyau chargé positivement et entouré d'un nuage d'électrons chargés négativement. Le facteur fondamental qui distingue un élément d'un autre est le nombre de protons à l'intérieur du noyau, connu sous le nom de *nombre atomique*. Le nombre de protons dans un atome est balancé par le nombre d'électrons chargés négativement, donnant ainsi à l'atome une charge neutre. Si un électron est enlevé ou additionné à l'atome, on dit que ce dernier a été *ionisé*.

C'est le nombre d'électrons dans un atome non-ionisé qui détermine son comportement chimique.

2.2.1 La désintégration radioactive

La plupart des éléments se trouvant dans la nature sont stables et conservent indéfiniment la même structure. Cependant, la majeure partie des éléments connus sont instables et subissent des transformations qui les mènent à un état plus stable. Ce processus, connu sous le nom de la *désintégration radioactive* altère la masse et/ou l'énergie du noyau, et se produit en un laps de temps allant de quelques secondes à un million d'années. Le passage d'un état instable à un état stable est accompagné d'émission de particules nucléaires (alpha et bêta) et de rayons gamma⁵.

2.2.2 Le traceur radioactif

L'acquisition d'images SPECT en médecine nucléaire commence par l'injection d'une substance radioactive dans le corps du patient. La désintégration radioactive est un phénomène entièrement aléatoire. Aussi, pour un traceur donné, quelques-uns des

5. Les rayons gamma forment une partie du spectre électromagnétique. Les rayons gamma émis par le Technetium-99m, le traceur radioactif le plus utilisé en médecine nucléaire, sont 100,000 fois plus puissants qu'un photon de la partie visible du spectre (PATTERSON et WYPER 1997).

atomes seront désintégrés après un laps de temps très court et d'autres le seront après une période plus prolongée. Il est important de savoir que la substance radioactive ne doit pas subsister indéfiniment dans le corps du patient, mais doit se désintégrer, et ce, après un temps connu en physique sous le nom de *période de demi-vie*. De plus, la radioactivité est éliminée du corps par un processus biologique naturel. En médecine nucléaire, un traceur efficace doit donc posséder les caractéristiques suivantes⁶ :

- Il doit émettre des photons d'une énergie allant de 100 à 200 KeV afin qu'ils soient efficacement mesurés par la caméra gamma.
- Il ne doit pas contenir de particules alpha (noyau d'hélium) qui sont dangereuses pour le patient et très peu de particules bêta (électrons rapides). Ces deux particules ne contribuent pas à la formation de l'image.
- Il doit avoir une période de demi-vie appropriée (mesurée en minutes ou heures, ce qui correspond au temps d'acquisition de l'image).

2.2.3 Mesure de radiation

Les photons émis par le traceur radioactif interagissent avec les électrons des atomes des tissus du corps de deux façons différentes :

Absorption : Les photons peuvent passer toute leur énergie à l'électron. Ils sont donc entièrement absorbés par les tissus, d'où résulte une réduction du signal détecté. C'est pour cette raison que la plupart des systèmes SPECT incorporent dans leurs algorithmes de reconstruction le facteur *d'absorption*. Ce phénomène est illustré par l'événement "D" dans le schéma 2.2.

Dispersion compton : Les photons peuvent aussi ne passer qu'une partie de leur énergie à l'électron, ce qui les pousse à dévier vers différentes trajectoires, l'information spatiale que porte le signal est alors erronée. L'énergie du photon est, elle aussi changée dans ce processus, et est réduite d'une quantité dépendante de l'angle par lequel

6. Le Technetium-99m comprend toutes ses qualités, et est le traceur le plus utilisé en SPECT.




FIG. 2.2 – Détecteur de scintillations et les différentes interactions des rayons gamma—
Modifiée de (Jaszczak, Coleman et Lim 1980)

la trajectoire du photon a été altérée. Pour cette raison, un analyseur d'énergie, connu sous le nom de *fenêtre énergétique* est utilisé, rejetant tous les photons d'énergie inférieure à des limites prédéfinies. Cette fenêtre permet aussi de réduire les radiations de l'environnement incluses dans l'image. Ce phénomène est illustré par l'événement "C" dans le schéma 2.2.

2.2.4 Le détecteur de radiation en SPECT et imagerie tomographique

Tous les systèmes SPECT (figure 2.3) utilisent un détecteur de radiations simple et efficace connu sous le nom de *détecteur de scintillations*. Le détecteur comprend un cristal d'iodure de sodium, un tube photomultiplicateur, un analyseur d'énergie électronique et un compteur qui rejette le signal émis par les photons avec des énergies erronées (voir le schéma 2.2).

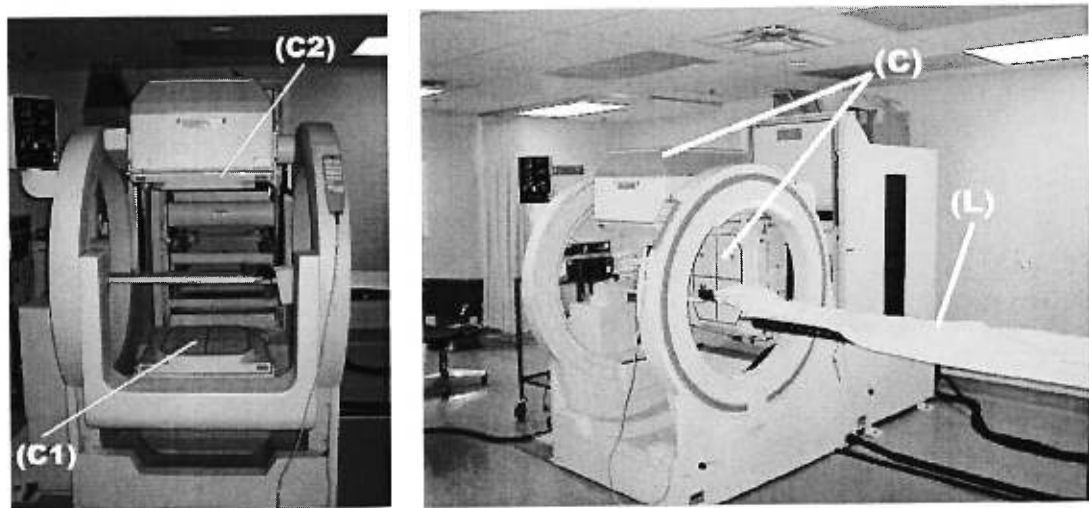


FIG. 2.3 – Appareillage du système SPECT. Les caméras (C1) et (C2) sont à un angle de 180° l'une de l'autre, tandis que (C) les représente à 90° l'une de l'autre. (L) est le lit du patient

Les scintillations dans le cristal apparaissent lors des ionisations, c'est-à-dire lorsque les photons sont absorbés via les effets photoélectriques et comptons. Les scintillations lumineuses sont alors converties en courant électrique par le tube multiplicateur. Ainsi, la caméra gamma utilisée en médecine nucléaire est pourvue de plusieurs dizaines de tubes multiplicateurs, ayant pour fonction de rassembler les signaux émis

par les différentes parties du cristal. Enfin, le détecteur comprend un collimateur en plomb qui entoure le cristal (PATTERSON et WYPER 1997). Il existe plusieurs types de collimateurs: le parallèle, le convergent, le divergent et le «trou d'épingle». Le rôle du collimateur est de laisser passer uniquement les photons qui arrivent presque perpendiculairement à la surface du cristal (ce phénomène est illustré par les événements "C" et "B" dans le schéma 2.2), les autres étant arrêtés par le septa (ce phénomène est illustré par l'événement "A" dans le schéma 2.2) (ROUSSIN 1993). Dans une caméra gamma planaire conventionnelle, l'orientation du collimateur ainsi que le nombre et la position des tubes multiplicateurs sont combinés pour former une image 2D. Pour obtenir des images tomographiques 3D, la caméra effectue une rotation autour du patient (180° ou 360°). Des projections sont alors obtenues sous une trentaine ou une soixantaine d'angles de vues différents. Chacune de ces projections est ensuite filtrée numériquement et rétro-projetée de façon à former un cube d'intérêt de résolution $N \times N \times M$. Où M est le nombre de tranches de dimension $N \times N$. Typiquement, le cube tomographique est composé de $64 \times 64 \times 64$ voxels, la valeur de chaque voxel correspond à l'intensité relative de radioactivité. En fait, l'image 3D obtenue en médecine nucléaire n'est pas directement utilisée en clinique; la plupart des systèmes médicaux affichent plutôt sur les écrans des ordinateurs des images 2D (voir la figure 2.4).




FIG. 2.4 – Représentations 2D de vingt-et-une tranches transverses d'un cerveau

Pour y arriver, le cube 3D est subdivisé en tranches successives selon les trois axes cartésiens X (transverse), Y (sagittal) et Z (frontal ou coronal). On affiche ensuite simultanément les coupes tomographiques ((DILHUYDY 1991) et (GORIS, BOUDIER et BRIANDET 1986)). L'orbite de rotation de la tête de la caméra gamma est décisive pour l'obtention d'une image finale de qualité. Elle doit donc, à chaque moment, être le plus proche possible du patient. Ceci permet de maximiser la collecte de photons et d'optimiser la résolution du système. C'est pour cette raison que de nos jours, la majorité des caméras suivent une trajectoire en forme d'ellipse (PATTERSON et WYPER 1997).

2.3 Avantages de l'imagerie SPECT

Une étude effectuée par KEYES (1982) démontre que seulement 15% à 20% des patients auront accès à la technologie SPECT, puisqu'elle tend à être substantiellement plus coûteuse que l'imagerie planaire. Pourtant elle reste la méthode par excellence car:

- L'imagerie par SPECT permet l'acquisition d'informations à partir d'un cercle complet autour du patient. Il n'est donc pas nécessaire de prendre des images à partir d'angles spécifiques pour chaque type d'organe.
- Elle permet au médecin de voir derrière les organes.
- Elle permet de séparer l'arrière-plan de la cible, ce qui améliore nettement le contraste des images.
- Il est plus facile avec SPECT de localiser anatomiquement les lésions ainsi que d'obtenir des informations sur ces dernières.
- SPECT peut être un outil efficace non seulement pour les descriptions en 3D des lésions dans des organes tels que le cœur ou le foie, mais peut aussi aider à examiner des structures plus complexes.
- Finalement, la caméra Anger est plus efficace que les autres caméras connues de nos jours (CROFT 1986).

Pour toutes ces raisons, la tomographie par émission de photon unique contrôlée par ordinateur est devenue une technologie facilement accessible et très utilisée en médecine nucléaire. Dans la littérature récente on peut retrouver diverses applications du SPECT: par exemple, Roger et al. (1996) utilisèrent les images SPECT de cerveaux afin de détecter la maladie des caissons qui atteint les plongeurs et ce, en se basant sur l'analyse des textures. Staff et al. (1995), Macleod et al. (1988), EVANS (1994) et Wilmshurst et al. (1993) aussi s'intéressèrent à la «maladie des plongeurs» ainsi qu'à l'imagerie SPECT.

2.4 Inconvénients de l'imagerie SPECT

L'un des problèmes majeurs de l'imagerie SPECT est la médiocre qualité des images reconstruites, NOUMEIR (1994) identifie trois principaux facteurs contribuant à ce problème:

- Les processus de l'émission radioactive, ainsi que celui de la détection des photons émis étant des phénomènes aléatoires, les images sont généralement très bruitées.
- La réponse impulsionnelle (PSF) de la caméra dépend de la distance entre la source et la caméra. Cette variation de la PSF introduit des distorsions et diminue considérablement la résolution.
- Une grande partie des photons émis par le traceur radioactif ne sera pas enregistrée par la caméra, et ce, soit parce que la majeure partie des photons sera absorbée par le corps du patient ou alors, parce que leur énergie sera inférieure à la limite détectable. Retenons aussi que la dose radioactive administrée au patient n'est pas assez forte pour pouvoir utiliser des détecteurs à résolutions intenses. Pour toutes ces raisons, les images résultantes seront à faibles comptes.

D'autres problèmes peuvent être également cités (CROFT 1986):

- L'intensité de la source d'émission, sa position et la distribution des atténuations sont toutes inconnues.
- La source est de si faible intensité, que les comptes doivent être décrits à l'aide de la loi de Poisson dans un domaine où les incertitudes mathématiques concernent une grande partie des comptes.
- Les formulations mathématiques en reconstruction SPECT semblent former des incertitudes pire qu'elles ne le sont en imagerie planaire.
- La résolution des images en SPECT dépend de la résolution de la caméra; aussi, ces dernières années les améliorations dans la résolution de la caméra Anger n'ont pas été très importantes.
- En plus des incertitudes dues à la caméra s'ajoutent les incertitudes dues aux mouvements du patient.
- Il existera toujours des patients plus larges que le champ de vision de la caméra, ce qui occasionnera des problèmes lors de la reconstruction.

Chapitre 3

L'analyse des textures

Il est toujours facile de différencier visuellement une texture d'une autre; il est à la portée de tous de voir la différence existante entre des cheveux ondulés et des cheveux droits, des briques et de l'herbe, de la fourrure et de la soie. Il existe dans la nature autant de textures qu'il y a d'éléments visibles et, l'œil humain sera toujours capable ou presque, de les différencier, sans pour autant savoir à quelle classe de textures elles appartiennent. La figure 3.1 présente quelques exemples de textures.




FIG. 3.1 – Exemples de textures—Tirées de (Heckbert 1997)

La grande multiplicité des textures, de même que l'impossibilité de donner à ce concept une définition précise, fait de l'analyse par ordinateur une tâche ardue et compliquée. L'un des problèmes est de mesurer les attributs des textures à l'aide desquels une série d'images sera classifiée. C'est pour cela que ce domaine est un domaine de recherche très actif. Comme souligné par GREENSPAN, GOODMAN, CHELLAPPA et ANDERSON (1994): «*Bien que l'analyse des textures ait été un sujet d'études intenses par plusieurs chercheurs, il reste que ce domaine est encore ouvert à de meilleurs résultats de classification ...*»

Aujourd'hui une grande quantité d'ouvrages est publiée et beaucoup de méthodes sont appliquées et développées dans le but d'obtenir les attributs les plus représentatifs des textures et de meilleurs résultats de classification. Bien que les méthodes d'analyses et de classifications des textures diffèrent, il reste que les étapes d'analyse sont les mêmes, c'est à la définition des textures et des étapes d'analyse que ce chapitre est consacré.

3.1 Définition de la texture

La texture est l'une des plus importantes caractéristiques de l'image. Elle est analysée afin d'identifier des objets ou des régions qui nous intéressent dans une image.

Il convient tout d'abord de définir ce qu'est une texture. Pour ce faire, nous effectuons un survol des définitions offertes dans la littérature. Pour commencer, on ne peut parler de textures sans citer BORDATZ (1956), qui fut le premier à proposer des exemples photographiques de différentes textures naturelles. Ces images sont utilisées comme images test en analyse de texture, car elles sont beaucoup plus réalistes que celles générées par ordinateur.

Notons que plusieurs auteurs s'accordent pour dire que «*la notion de texture est un concept qui n'a pas trouvé de définition usuelle satisfaisante*» (REUZÉ 1995), (TAMURA

1978), (HARALICK, SHANMUGAM et DINSTEIN 1973), (BURRILL 1997), (DUBES et JAIN 1989) et (CROSS et JAIN 1983).

REUZÉ (1995) propose cependant cette définition:

«Étant donné qu'une image est constituée de contours et de régions texturées, on peut définir la partie texture d'une image comme tout ce qui n'est pas contour; mais cette définition doit être complétée par la définition du contour».

De leur côté HARALICK, SHANMUGAM et DINSTEIN (1973) évaluent la qualité d'une texture en termes d'adjectifs comme la grossièreté, l'irrégularité, la finesse, l'ondulation, l'orientation et la rayure. Par exemple, ils constatent que sur une image radar d'une région des tropiques humides, une texture fine de l'image indique des rochers non résistants et des sédiments non consolidés, tandis qu'une texture grossière indique des rochers granuleux et grossiers. Une texture massive formée de composantes à fort contraste représente quant à elle des rochers ignés.

HARALICK, SHANMUGAM et DINSTEIN (1973) présentent la texture ainsi:

«La texture est une propriété innée de toutes les surfaces: les brins de bois, les motifs d'une récolte dans un champ, les ondulations d'un tissu, etc. Elle contient d'importantes informations sur les arrangements structurels des surfaces. Comme les propriétés textuelles d'une image portent d'importantes informations à des fins de discriminations, il est important de développer les attributs de la texture».

TAMURA (1978) identifie six attributs perceptibles d'une texture: la grossièreté, le contraste, l'orientation, la linéarité¹, la régularité et la rugosité.

En segmentation, la texture permet de décrire la répétition de certains motifs dans une image. En d'autres termes, la texture permet de décrire la corrélation entre différentes parties d'une région d'une image, ou de regrouper des parties similaires d'une image en une seule région (ZHANG 1996).

1. *Line-likeness*

BURRILL (1997) départage les textures en deux types :

- Les textures *statistiques*, qui sont définies comme étant des distributions spatiales des intensités dans une image, conformément à des modèles probabilistiques fondamentaux.
- Les textures *structurées*, elles sont définies comme étant des distributions spatiales d'un ensemble de primitives dans une image, conformément à des lois de placement prédéfinies.

Similairement, REUZÉ (1995) départage les textures en deux types :

- Les textures structurées, définies comme celles constituées de répétition d'une primitive à intervalles réguliers. À cette catégorie appartiennent les textures parfaitement périodiques (carrelage), ou celles dont les primitives subissent des déformations ou/et des changements d'orientation (peau de crocodile). En imagerie médicale, il est rare de rencontrer des textures structurées, mais cela est possible comme dans le cas des tissus osseux.
- Les textures aléatoires, définies comme celles composées d'organisations statistiques particulières des niveaux de gris (crépis et sable). Elles sont reconnues comme étant plus fines que les textures structurées. En imagerie médicale, la plupart des textures sont de type aléatoire, comme par exemple, les tissus mous (matières grise et blanche du cerveau, muscles ou graisse).

BURRILL (1997), ne donne pas de définition concrète à la texture, mais affirme que l'analyse de la texture est effectuée pour deux raisons majeures :

- La caractérisation des textures inconnues, correspondant à différents objets dans une image — les images satellites par exemple.

- L'identification des différentes parties d'une texture à des fins de rehaussement², pour les images médicales par exemple (rehaussement des tumeurs pour une meilleure visualisation).

En nous basant sur ces définitions, il est maintenant évident que les textures qui nous intéressent sont de type statistique, étant donné que nous utilisons des images médicales SPECT de cerveaux.

3.2 Les étapes d'analyse des textures

L'analyse des textures joue un rôle important dans la vision humaine, la vision par ordinateur, la reconnaissance des formes et l'analyse d'images digitales. Elle est utilisée afin de détecter et distinguer des régions et des objets dans une image (COHEN et FEIGENBAUM 1982), pour la synthèse d'images (CROSS et JAIN 1983), la segmentation (CHEN et PAVLIDIS 1979), (REUZÉ 1995), ou pour la classification (HARALICK, SHANMUGAM et DINSTEIN 1973), (HARALICK et SHANMUGAM 1973), (GOTLIEB et KREYSZIG 1990), (WALKER 1996), (OHANIAN et DUBES 1992), (CHEN, NIXON et THOMAS 1995), (VICKERS et MODESTINO 1982), (WESZKA, DYER et ROSENFELD 1976), (CONNERS et HARLOW 1980), (MODESTINO, FRIES et VICKERS 1981) et (PELEG, NAOR, HARTLEY et AVNIR 1984).

Cette section décrit les différentes étapes qui sont typiquement utilisées en analyse de textures et, plus spécifiquement, en classification. Le schéma 3.2 présente les composantes principales d'un algorithme de classification de textures.

2. Les techniques de rehaussements permettent de traiter une image digitale de sorte à en générer une nouvelle plus exploitable que l'originale dans le cadre d'applications spécifiques (GONZALEZ et WOODS 1992).

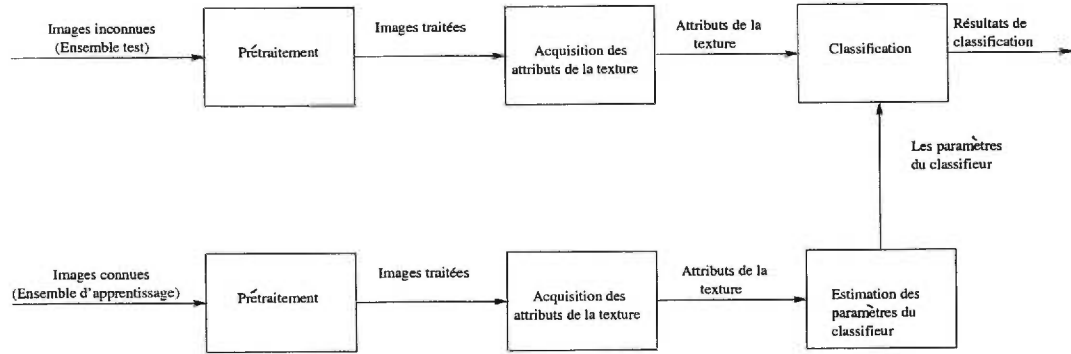


FIG. 3.2 – Diagramme des étapes de classification des textures

Dans le domaine du traitement d'images, la classification automatique des textures est un problème de taille: l'image numérique est sensée contenir de l'information qui la fait appartenir à l'une des classes de textures connues *a priori*. Il est toujours souhaitable d'assigner cette image à une classe correcte en se basant sur les mesures prises sur tout l'ensemble de l'image. Les étapes de classification sont décrites dans (SMITH 1998), (VICKERS et MODESTINO 1982) et (HAND 1981). La première étape qui précède toute classification est bien entendu :

a) **L'étape d'acquisition des images:** Le but de cette étape est d'obtenir des images numériques, ce qui nécessite deux éléments distincts:

- Un appareillage sensible à une partie du spectre électromagnétique—les rayons X, l'infrarouge, la lumière visible ou les ultraviolets. Cet appareil doit être également capable de produire un signal électrique proportionnel au niveau d'énergie perçu.
- Un *numériseur*, qui convertit le signal électrique sous forme numérique.

En médecine nucléaire, par exemple, les données sont enregistrées dans l'ordinateur directement à partir de la caméra gamma. Par le biais d'une interface, l'ordinateur reçoit de la caméra de l'information sur la position des scintillations³ et signale à la caméra quand elle doit tourner ou prendre une nouvelle image.

³ Le fonctionnement de la caméra gamma ainsi que la provenance des scintillations sont décrits dans le chapitre sur l'imagerie SPECT.

L'interface est un système électronique codant les signaux émis par la caméra de sorte qu'ils soient acceptés par le processeur de l'ordinateur. Les signaux émis par la caméra Anger sont sous forme de voltages continus ou analogues. La valeur du voltage représente la valeur des paramètres spécifiques, tels les positions X et Y des scintillations. Dans certains cas, le signal analogue est transmis à un convertisseur analogue numérique avant d'être traité par l'ordinateur. D'autres types de caméras Anger émettent des signaux numériques directement à l'ordinateur. Pour terminer, l'information envoyée par la caméra à l'ordinateur est enregistrée par celui-ci en format image et est alors prête à être utilisée (CROFT 1986), (SPRAWLS 1981).

La classification nécessite l'utilisation de deux groupes d'images: le premier, que l'on nommera *ensemble test*, est composé d'images inconnues, appartenant à une classe de textures elle aussi inconnue, que l'on désire déterminer; le second groupe, que l'on nommera *ensemble d'apprentissage*, composé d'images connues, appartenant à une classe de textures connue *a priori*. Le but de l'ensemble d'apprentissage est d'adapter le classifieur à chaque classe de textures possible avant que l'ensemble test ne soit appliqué au classifieur. Les deux groupes d'images passent alors par la deuxième étape d'analyse qui est:

- b) **Le prétraitement:** Il est question ici de préparer les images à l'étape d'extractions des attributs, de façon à augmenter les chances de succès de la classification. On applique pour cela sur les images des fonctions comme *la normalisation*, afin d'éliminer des effets indésirables tels que les changements d'illumination et de résolution, *le rehaussement de contraste* et *la réduction du bruit*. Pour plus de détails sur ces trois fonctions le lecteur peut consulter par exemple l'ouvrage de (GONZALEZ et WOODS 1992). On retrouve dans la littérature l'application d'une autre fonction, *la quantification des niveaux de gris*, utilisée si le calcul des attributs ainsi que la classification dépendent de l'étendue des variations des niveaux de gris d'une image. Le but de cette fonction est de quantifier les niveaux de gris de l'image de telle sorte que l'étendue en question soit la plus réduite

possible. Notons que le choix de la taille de l'étendue revient à l'analyseur, qui doit la choisir telle que les images ne perdent pas de l'information utile à l'analyse. Il est également important de noter que la quantification doit être identique sur l'ensemble des images à analyser. Les méthodes de quantifications usuelles sont proposées par (HARALICK, SHANMUGAM et DINSTEIN 1973), (VICKERS et MODESTINO 1982) et (PRATT 1978). Par la suite les deux groupes (test et apprentissage) passent par l'étape suivante :

- c) **Acquisition des attributs de la texture:** Cette étape est l'une des plus importantes en analyse de texture. Elle consiste à calculer un vecteur d'attributs unique pour chaque image (HARALICK, SHANMUGAM et DINSTEIN 1973), (VICKERS et MODESTINO 1982), (CHEN, NIXON et THOMAS 1995), (WALKER 1996). Ce processus transforme l'information implicite d'une texture en un vecteur d'attributs où l'information texturale est plus saillante. Ainsi, chaque attribut révèle des propriétés de la texture, telles que la rugosité, l'orientation, le contraste, etc. (SMITH 1998). Plusieurs méthodes sont possibles pour l'extraction des attributs et la plupart d'entre elles sont décrites en détail dans le prochain chapitre. De façon générale, cette étape permet l'acquisition d'attributs à l'aide desquels il sera possible d'extraire par la suite de l'information utile sur les textures, tout en réduisant la quantité des données à traiter dans les prochaines étapes. Notons que pour tout problème de classification, il est toujours possible de mesurer sur chaque image un très grand ensemble d'attributs, mais qu'il est préférable de choisir un sous-ensemble de ce dernier, propre à obtenir de bons résultats de classification. Ceci permettra de réduire le temps des calculs et d'éliminer les redondances, car il n'y a aucun avantage à calculer et utiliser une variable qui n'ajoute rien à l'obtention de bons résultats de classification. Cependant, comme il est difficile de choisir intuitivement un sous-ensemble d'attributs à partir d'un ensemble donné, plusieurs approches statistiques ont été développées. Quelques-unes sont décrites dans (HAND 1981). Cette étape sera explorée

dans le chapitre 4. Après avoir choisi et calculé les attributs, l'ensemble d'apprentissage seulement passe par l'étape suivante :

- d) **Estimation des paramètres du classifieur:** Dans cette étape, il est question d'utiliser les attributs calculés à partir de l'ensemble d'apprentissage afin d'estimer les paramètres qui serviront à adapter le classifieur à chaque type de texture possible. Ces paramètres peuvent être, par exemple, le vecteur de la moyenne et la matrice de covariance, utilisés dans le cas du *classifieur de Bayes*. Cette étape sera explorée dans le chapitre 5. Finalement l'ensemble test passe par l'étape finale qui est :
- e) **La classification:** L'étape de classification automatique explore des techniques capables d'assigner chaque type de texture à sa classe appropriée, automatiquement, avec une intervention humaine subséquente. Chaque texture est représentée par: soit un vecteur d'attributs (dans le cas de descriptions quantitatives) ou alors des chaînes ou des arbres (dans le cas de descriptions structurelles). Pour le cas qui nous intéresse, les descriptions quantitatives, les méthodes principales de classifications utilisées sont le *classifieur de distance minimum*, les *corrélateurs*, le *classifieur de Bayes* et les *réseaux de neurones*. Ces méthodes sont décrites en détail dans (GONZALEZ et WOODS 1992) et au chapitre 5. Dans le cas de descriptions quantitatives, le principe de classification reste le même indépendamment de la méthode choisie. C'est celui du calcul des *fonctions de décision* ou *fonctions discriminantes*.

Les deux prochains chapitres sont entièrement consacrés à la description détaillée des trois dernières étapes de l'analyse des textures.

Chapitre 4

Les attributs de la texture

Comme nous l'avons vu plus haut, bien que les chercheurs ne s'entendent sur aucune définition formelle de la texture, la plupart s'accordent pour dire qu'une texture exhibe des propriétés telles que la rugosité, le contraste, la grossièreté, la finesse, etc. La troisième étape d'analyse de texture, *l'acquisition des attributs*, a été développée dans le but d'extraire des attributs permettant de décrire la texture d'une image. Les méthodes utilisées pour ce faire découlent de quatre approches fondamentales (GONZALEZ et WOODS 1992):

- (a) *Approche statistique* : cette méthode permet d'identifier une texture et de la caractériser comme étant grossière, lisse, granuleuse, etc., à partir de mesures statistiques sur l'image.
- (b) *Approche structurelle* : cette technique étudie l'arrangement des primitives dans une image¹. Elle permet, par exemple, de décrire une texture en se basant sur la régularité du placement des primitives.
- (c) *Approche spectrale* : cette méthode, basée sur les propriétés du spectre de Fourier, est entre autres utilisée afin de détecter les périodicités au sein d'une image, en identifiant les pics dans le spectre.

1. Le terme primitive dans ce contexte est utilisé dans le sens de composante individuelle, et non dans le sens de composante non développée.

(d) *Approche basée sur la modélisation des textures* : dans ce cas, une texture est considérée comme étant le résultat d'un processus stochastique gouverné par un certain nombre de paramètres. Le processus d'analyse de la texture est perçu comme un problème d'estimation des différents paramètres. Ces derniers peuvent par la suite servir comme attributs de la texture et seront utilisés en classification et segmentation des textures. La difficulté avec cette approche réside dans le fait que la plupart des textures naturelles ne sont pas conformes aux restrictions d'un modèle particulier (DUBES et JAIN 1989).

La suite de ce chapitre sera consacrée à la définition des différents attributs employés dans chaque approche.

4.1 Méthodes statistiques

Puisque les images médicales que l'on se propose d'étudier dans ce mémoire sont plus de nature aléatoire, les méthodes d'analyse statistiques présentent le plus d'intérêt. On définit *l'ordre* d'une statistique par le nombre de pixels mis en jeu dans son calcul (REUZÉ 1995). JULESZ (1962 ; 1975) a déterminé que l'œil humain est capable de distinguer deux textures ayant des statistiques de premier ordre² différentes (par exemple la moyenne et la variance), ou encore entre deux textures ayant les mêmes statistiques de premier ordre, mais des statistiques de second ordre³ différentes (par exemple la corrélation). Par contre, l'observateur sera incapable de distinguer deux textures dont les statistiques d'ordre supérieur à deux sont différentes. C'est pour cette raison que les chercheurs ont porté une attention particulière aux statistiques du premier et second ordre (BURRILL 1997). Les méthodes statistiques les plus utilisées en

2. Les statistiques de premier ordre sont celles qui utilisent dans leurs calculs l'intensité d'un seul pixel.

3. Les statistiques du second ordre sont celles qui comparent les différences entre les intensités de deux pixels localisés à deux endroits différents.

analyse de texture sont celles des *moments statistiques*, des *matrices de cooccurrences*, et des *différences de niveaux de gris*.

4.1.1 Les moments statistiques

Calculer l'histogramme d'une image est considéré comme le moyen le plus simple de décrire une texture. Cette technique consiste à extraire les attributs du premier ordre qui sont les moments de l'histogramme des niveaux de gris de l'image à analyser. Soit $p(i)$, $i = 0, 1, \dots, N_g - 1$, l'histogramme de l'image, où N_g est le nombre total des niveaux de gris distincts et i , une variable aléatoire dénotant une intensité de l'image. Chaque point de l'histogramme représente la probabilité qu'une intensité i apparaisse dans l'image. Plusieurs attributs peuvent être calculés à partir de l'histogramme, les plus courants étant la moyenne (équation 4.1), les moments (équation 4.2) et l'entropie (équation 4.3).

$$\mu = \sum_{i=0}^{N_g-1} ip(i) \quad (4.1)$$

$$\eta_n = \sum_{i=0}^{N_g-1} (i - \mu)^n p(i) \quad (4.2)$$

$$\text{Entropie} = \sum_i^{N_g-1} p(i) \log\{p(i)\}. \quad (4.3)$$

La moyenne est calculée afin de déterminer le niveau d'intensité moyen de la texture; l'entropie, pour mesurer l'uniformité de l'histogramme. Pour ce qui est des moments, il est clair d'après l'équation 4.2 que $\eta_0 = 1$ et $\eta_1 = 0$, alors que η_2 représente la variance et fournit de l'information sur les variations des intensités dans toute l'image; c'est donc une mesure de contraste qui permet d'établir si la texture est lisse.

Si $n = 3$, il est alors question du troisième moment, représentant l'asymétrie⁴. Cet attribut est égal à zéro si l'histogramme est symétrique de part et d'autre de la

4. Skewness

moyenne, sinon il a une valeur positive ou négative selon que l'histogramme est asymétrique du côté droit ou gauche de la moyenne. Autrement, si $n = 4$, le moment est alors de quatrième ordre et représente l'aplatissement⁵, la mesure (comme son nom le suggère) de l'aplatissement de l'histogramme. Si on compare à une distribution normale, une valeur d'aplatissement supérieure à $3\mu^2$ indique que les niveaux de gris se trouvent plus concentrés autour de la moyenne, tandis qu'une valeur d'aplatissement inférieure à $3\mu^2$ indique que les valeurs sont distribuées plus uniformément aux alentours de la moyenne.

Ces méthodes ne sont cependant pas suffisantes, puisqu'elles ne fournissent aucune information sur la position des pixels de l'image relativement les uns aux autres. Une méthode plus efficace serait d'introduire une telle information dans le processus d'analyse et de considérer non seulement la distribution des intensités mais aussi, la position des pixels d'intensités identiques (BURRILL 1997 ; GONZALEZ et WOODS 1992 ; REUZÉ 1995), ce qui correspond à la méthode de calcul des matrices de cooccurrences.

4.1.2 Les matrices de cooccurrences

Cette méthode statistique est probablement la plus utilisée en pratique, en dépit du fait qu'elle présente certains inconvénients : coût de calcul élevé et multiplicité des paramètres. On retrouve sa description dans plusieurs ouvrages, notamment dans (GONZALEZ et WOODS 1992), (PRATT 1978), (POSTAIRE 1987), ainsi que (SMITH 1998), (REUZÉ 1995), tandis que son application en analyse de texture est décrite dans de nombreux articles : WALKER (1996) utilisa les attributs des matrices de cooccurrences afin de classifier des cellules cervicales ; WESZKA, DYER et ROSENFELD (1976) et HARALICK, SHANMUGAM et DINSTEIN (1973) les utilisèrent pour la classification d'images satellites ; HARALICK et SHANMUGAM (1973) pour la classification d'images de grès ; FREEBOROUGH et FOX (1998) et BURRILL (1997) utilisèrent les attributs de

5. Kurtosis

texture extraits à l'aide des matrices de cooccurrences sur des IRM⁶ afin de diagnostiquer la maladie d'Alzheimer ; CHEN et PAVLIDIS (1979) utilisèrent les matrices de cooccurrences pour la segmentation des textures ; OHANIAN et DUBES (1992) montrèrent que les attributs des matrices de cooccurrences classifient des textures de l'album de Bordatz mieux que les attributs d'un champ de Markov aléatoire, des fractales et du filtre de Gabor ; CONNERS et HARLOW (1980) démontrèrent que cette méthode est meilleure que la méthode des longueurs de plages, la méthode des différences de niveaux de gris ou la méthode du spectre de Fourier. Afin de définir les matrices de cooccurrences et ses attributs, nous nous basons surtout sur HARALICK, SHANMUGAM et DINSTEIN (1973), qui furent les premiers à les introduire en analyse de texture.

Quelques définitions : L'information pictorielle est représentée comme une fonction de deux variables (x,y) . L'image 2D numérique est emmagasinée dans l'ordinateur sous forme d'une matrice à deux dimensions. Si $L_x = 1,2,\dots,N_x$ et $L_y = 1,2,\dots,N_y$ sont deux domaines spatiaux X et Y , alors $L_x \times L_y$ est un ensemble de pixels et l'image numérique $I : L_x \times L_y \rightarrow G$ est une fonction qui attribue un niveau de gris de l'ensemble $G \in \{0,1,2,\dots,N_g - 1\}$ à chacun des pixels.

Matrices de cooccurrences : La supposition essentielle de HARALICK, SHANMUGAM et DINSTEIN (1973) est que l'information relative à la texture d'une image I est contenue dans la relation spatiale « moyenne » qu'a chaque niveau de gris de cette image avec son voisin. Plus exactement, ils ont considéré que l'information sur la texture de l'image I est adéquatement spécifiée par la *matrice des fréquences relatives* :

$$F(d,\theta) = [P(i,j|d,\theta)],$$

où chaque élément de la matrice représente la probabilité de passer d'un pixel de niveau de gris i à son voisin de niveau de gris j , sachant que la distance entre eux est d et la direction, θ . Aussi, on peut dire que les matrices de cooccurrences contiennent

6. Image par résonance magnétique

les valeurs qui résument la dépendance spatiale des niveaux de gris, chacune des matrices étant associée à une distance entre pixels d et une direction d'angle θ (REUZÉ 1995). Formellement, si l'on se réfère à HARALICK, SHANMUGAM et DINSTEIN (1973), pour des angles quantifiés à intervalles de 45° , on obtient quatre groupes de matrices de cooccurrences principales $F(d,0^\circ)$, $F(d,45^\circ)$, $F(d,90^\circ)$ et $F(d,135^\circ)$, de dimensions $N_g \times N_g$, pour $d = 1, 2, \dots$

Finalement, afin d'obtenir de véritables fréquences relatives $p(i,j)$, les éléments des matrices doivent être normalisés en les divisant par le nombre total de paires de points R séparés par la distance d dans la direction θ , pour l'ensemble de l'image analysée. D'où la relation:

$$p(i,j) = \frac{P(i,j)}{R}.$$

Les attributs de texture : Les matrices de fréquences (cooccurrences) ainsi obtenues permettent de calculer les attributs qui reflètent les propriétés de l'organisation spatiale d'une texture. Les paramètres les plus couramment utilisés en analyse de texture sont le *second moment angulaire*, le *contraste*, la *corrélation*, et l'*entropie*.

(a) *Second moment angulaire (énergie) :*

$$f_1 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \{p(i,j)\}^2. \quad (4.4)$$

Cette mesure définit l'*hétérogénéité* de la texture (POSTAIRE 1987). Elle est petite lorsque toutes les valeurs des $p(i,j)$ sont égales. Par contre, elle est grande, lorsque quelques valeurs des $p(i,j)$ sont grandes et d'autres sont petites (WESZKA, DYER et ROSENFELD 1976).

(b) *Contraste :* Le contraste d'une texture est caractérisé par la somme pondérée des fréquences correspondant à différents écarts de niveaux de gris (POSTAIRE 1987). Il est

calculé comme suit:

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j) \right\}, n = |i - j|. \quad (4.5)$$

Cet attribut mesure le contraste ou les variations locales présentes dans une image (HARALICK, SHANMUGAM et DINSTEIN 1973). Plus les écarts entre les niveaux de gris sont importants, plus les fréquences sont fortement pondérées (amplifiées), si bien que la valeur calculée par cet attribut sera plus grande si la texture de l'image est très contrastée (POSTAIRE 1987).

(c) *Corrélation* : La dépendance directionnelle des niveaux de gris d'une texture est quantifiée par cet attribut, dont les valeurs les plus grandes sont atteintes lorsque l'angle θ est proche de l'orientation des lignes de la texture (POSTAIRE 1987). Mathématiquement, il est décrit comme :

$$f_3 = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (ij)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (4.6)$$

où μ_x , μ_y , σ_x et σ_y sont les moyennes et les écarts types des p_x et p_y , respectivement, et sachant que :

$$p_x(i) = \sum_{j=0}^{N_g-1} p(i,j), \quad p_y(j) = \sum_{i=0}^{N_g-1} p(i,j),$$

et

$$\begin{aligned} \mu_x &= \sum_{i=0}^{N_g-1} i p_x(i), & \mu_y &= \sum_{j=0}^{N_g-1} j p_y(j), \\ \sigma_x &= \sum_{i=0}^{N_g-1} (i - \mu_x)^2 p_x(i), & \sigma_y &= \sum_{j=0}^{N_g-1} (j - \mu_y)^2 p_y(j). \end{aligned}$$

Cet attribut permet également d'identifier le degré de ressemblance des colonnes (lignes) de la matrice de cooccurrences. La valeur de cet attribut est grande lorsque les valeurs sont uniformément distribuées dans la matrice, autrement cette valeur est petite (WESZKA, DYER et ROSENFELD 1976).

(d) *Entropie* : Cet attribut calcule la quantité d'information contenue dans une texture. Il est calculé comme :

$$f_4 = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j) \log\{p(i,j)\}. \quad (4.7)$$

La valeur de l'attribut est grande lorsque les $p(i,j)$ sont égaux et vice-versa (WESZKA, DYER et ROSENFELD 1976).

En plus de ces attributs, HARALICK, SHANMUGAM et DINSTEIN (1973) en proposent d'autres qui ont été largement utilisés, bien que moins populaires que les quatre précédents :

(e) *Moment différentiel inverse* :

$$f_5 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{1}{1 + (i - j)^2} p(i,j) \quad (4.8)$$

(f) *Somme des moyennes* :

$$f_6 = \sum_{k=0}^{2N_g-2} k p_{x+y}(k) \quad (4.9)$$

(g) *Somme des variances* :

$$f_7 = \sum_{k=0}^{2N_g-2} (k - f_6)^2 p_{x+y}(k) \quad (4.10)$$

(h) Somme des entropies :

$$f_8 = - \sum_{k=0}^{2N_g-2} P_{x+y}(k) \log\{p_{x+y}(k)\} \quad (4.11)$$

où

$$p_{x+y}(k) = \sum_{\substack{i=0 \\ i+j=k}}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j), \quad k = 0, 1, \dots, 2N_g - 2$$

(i) Différence des entropies :

$$f_9 = - \sum_{k=0}^{N_g} p_{x-y}(k) \log\{p_{x-y}(k)\} \quad (4.12)$$

où

$$p_{x-y}(k) = \sum_{\substack{i=0 \\ |i-j|=k}}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j), \quad k = 0, 1, \dots, N_g$$

(j) Information de corrélation 1 et 2 :

$$f_{10} = \frac{HXY - HXY1}{\max\{HY, HX\}} \quad (4.13)$$

$$f_{11} = (1 - \exp[-2.0(HXY2 - HXY)])^{\frac{1}{2}} \quad (4.14)$$

où

$$HXY = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j) \log\{p(i,j)\}$$

et HX et HY sont les entropies de p_x et p_y , et

$$HXY1 = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i,j) \log\{p_x(i)p_y(j)\}$$

$$HXY2 = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p_x(i)p_y(j) \log\{p_x(i)p_y(j)\}.$$

La méthode des matrices de cooccurrences est cependant incapable de différencier toutes les textures visuellement différentiables, et son calcul est très coûteux, surtout lorsqu'il est effectué pour plusieurs valeurs de d (REUZÉ 1995).

4.1.3 Les différences de niveaux de gris

La méthode des différences de niveaux de gris ressemble à la méthode des matrices de cooccurrences, mais elle ne permet pas de préserver l'information sur la valeur absolue des niveaux de gris d'une texture. En effet, si la méthode des matrices de cooccurrences calcule des matrices indexées par les niveaux de gris, celle des différences de niveaux de gris calcule des vecteurs indexés par les différences entre deux intensités voisines (SMITH 1998). Si l'on somme les éléments d'une matrice de cooccurrences le long des lignes parallèles à la ligne diagonale, nous obtenons alors le vecteur en question (WESZKA, DYER et ROSENFELD 1976). Au fond, cette méthode nous ramène à analyser la différence entre une image originale et sa copie translatée (POSTAIRE 1987). En nous référant à (WESZKA, DYER et ROSENFELD 1976), nous obtenons les définitions suivantes :

Pour une fonction $f(x,y)$ représentant une image numérique, soit $\delta \equiv (\Delta x, \Delta y)$ un déplacement donné, où Δx et Δy sont des entiers.

Le vecteur des différences de niveau de gris $p_\delta(i)$ est l'estimé de la fonction de densité de probabilité associée aux valeurs possibles de $f_\delta(x,y) = |f(x,y) - f(x +$

$\Delta x, y + \Delta y)$, tel que:

$$p_{\delta}(i) = P(f_{\delta}(x, y) = i).$$

En d'autres termes, pour N_g niveaux de gris, $p_{\delta}(i)$ aura la forme d'un vecteur N_g -dimensionnel, où à la position i du vecteur correspond la probabilité que $f_{\delta}(x, y)$ soit égale à i . Si l'image f est discrète, alors le calcul de $p_{\delta}(i)$ se fait en comptant le nombre de fois que $f_{\delta}(x, y)$ apparaît. Les attributs définissant une texture et calculés à partir de cette méthode sont le *contraste*, le *second moment angulaire*, l'*entropie*, de même que la *moyenne*.

(a) *Contraste* : Cet attribut est aussi connu sous le nom de *moment d'ordre deux*.

$$\text{CON} = \sum_{i=0}^{N_g-1} i^2 p_{\delta}(i) \quad (4.15)$$

Cette valeur est grande lorsqu'il y a beaucoup de grandes différences.

(b) *Second moment angulaire* :

$$\text{SMA} = \sum_{i=0}^{N_g-1} p_{\delta}(i)^2 \quad (4.16)$$

La valeur de cet attribut est minimisée pour des $p_{\delta}(i)$ tous égaux.

(c) *Entropie* :

$$\text{ENTR} = - \sum_{i=0}^{N_g-1} p_{\delta}(i) \log\{p_{\delta}(i)\} \quad (4.17)$$

la valeur de cet attribut est maximisée pour des $p_{\delta}(i)$ tous égaux.

(d) *Moyenne* :

$$\text{MOY} = \frac{1}{N_g} \sum_{i=0}^{N_g-1} i p_{\delta}(i). \quad (4.18)$$

Cet attribut est de petite valeur lorsque tous les $p_\delta(i)$ sont concentrés près de l'origine et grande, quand ils sont éloignés de l'origine.

Pour terminer, notons quelques remarques utiles offertes par WESZKA, DYER et ROSENFELD (1976) :

- Si la texture est rugueuse et la séparation δ petite (comparée à la taille de l'élément textural), les paires de points situées à cette distance auront probablement les mêmes niveaux de gris, de telle sorte que $f_\delta(x,y)$ sera aussi petit et les valeurs dans $p_\delta(i)$, concentrées près de $i = 0$.
- Pour une texture fine et une séparation δ comparable à la taille de l'élément textural, les paires de points situés à cette distance auront des niveaux de gris différents, de telle sorte que $f_\delta(x,y)$ sera aussi très grand et les valeurs dans $p_\delta(i)$, très étalées.
- Pour une texture directionnelle, le degré de déploiement des valeurs dans $p_\delta(i)$ variera avec la direction de δ .

4.1.4 Les matrices de longueurs de plages

GALLOWAY (1975) offre la définition suivante d'une longueur de plage⁷ : « *La longueur de plage est un ensemble de points image consécutifs et colinéaires, ayant les mêmes valeurs de niveaux de gris. La longueur d'une plage est caractérisée par le nombre de points image contenus dans la plage.* » Pour leur part, CONNERS et HARLOW (1980) suggèrent que « *la longueur de plage de niveaux de gris est le nombre de points image linéairement adjacents ayant les mêmes valeurs de niveaux de gris.* » Plus formellement, on définit $r(i,j|\theta)$ comme l'élément de la matrice de longueurs de plage $R(\theta)$ qui est toujours associé à un angle θ , tel que:

$$R(\theta) = [r(i,j|\theta)].$$

7. Run length

Ainsi, $r(i,j|\theta)$ spécifie le nombre de fois qu'une image contient des plages de niveaux de gris i , de longueur j dans la direction de l'angle θ . Pour chaque image, et pour un angle θ de valeur $0^\circ, 45^\circ, 90^\circ$ et 135° quatre matrices de longueurs de plages $R(\theta)$ sont calculées. Notons que pour le bon fonctionnement de cette méthode, il est utile de regrouper les niveaux de gris des images. Ceci a pour but de lisser les plages homogènes, qui seront alors détectées par une seule plage (REUZÉ 1995) et aussi, de diminuer le temps des calculs (BURRILL 1997). Soit N_g , le nombre des niveaux de gris dans l'image, N_r , le nombre de longueurs de plage présentes dans l'image, et T_r , le nombre total de plages dans l'image, tel que:

$$T_r = \sum_{i=0}^{N_g-1} \sum_{j=1}^{N_r} r(i,j|\theta).$$

Pour chacune des matrices $R(0^\circ), R(45^\circ), R(90^\circ)$ et $R(135^\circ)$ cinq attributs sont définis : le poids des plages courtes, le poids des plages longues, la distribution des niveaux de gris, la distribution des longueurs de plage, et le pourcentage des plages.

Le poids des plages courtes⁸ :

$$\text{PPC} = \frac{1}{T_R} \sum_{i=0}^{N_g-1} \sum_{j=1}^{N_r} \frac{r(i,j|\theta)}{j^2}. \quad (4.19)$$

Des valeurs élevées de l'attribut PPC indiquent la présence de lignes courtes (texture fine) dans la direction θ .

Le poids des plages longues⁹ :

$$\text{PPL} = \frac{1}{T_R} \sum_{i=0}^{N_g-1} \sum_{j=1}^{N_r} r(i,j|\theta) j^2 \quad (4.20)$$

Des valeurs élevées de l'attribut PPL indiquent la présence de lignes longues (texture allongée) dans la direction θ .

8. Short run emphasis

9. Long run emphasis

*La distribution des niveaux de gris*¹⁰ :

$$\text{DNG} = \frac{1}{T_R} \sum_{i=0}^{N_g-1} \left[\sum_{j=1}^{N_r} r(i,j|\theta) \right]^2. \quad (4.21)$$

L'attribut DNG est représentatif de l'uniformité des niveaux de gris parmi toutes les lignes découvertes. Cette valeur est petite lorsque les plages sont distribuées de façon égale sur les niveaux de gris.

*La distribution des longueurs de plages*¹¹ :

$$\text{DLP} = \frac{1}{T_R} \sum_{j=1}^{N_r} \left[\sum_{i=0}^{N_g-1} r(i,j|\theta) \right]^2. \quad (4.22)$$

L'attribut DLP rend compte de l'uniformité des longueurs de plage découvertes, quel que soit les niveaux de gris. Cette valeur est petite lorsque les longueurs de plage sont également distribuées.

*Le pourcentage des plages*¹² :

$$\text{PP} = \frac{1}{T_R} \sum_{i=0}^{N_g-1} \sum_{j=1}^{N_r} r(i,j|\theta). \quad (4.23)$$

Cette valeur est maximisée lorsque toutes les plages sont courtes. Par contre elle est petite lorsque les images contiennent des structures linéaires.

Deux autres attributs plus récemment introduits peuvent s'ajouter à cette liste (REUZÉ 1995) :

Le poids des longueurs de plage de faible niveaux de gris:

$$\text{PLPFb} = \frac{1}{T_R} \sum_{i=0}^{N_g-1} \sum_{j=1}^{N_r} \frac{r(i,j|\theta)}{i^2}. \quad (4.24)$$

10. *Gray level distribution*

11. *Run length distribution*

12. *Run percentages*

Le poids des longueurs de plage de fort niveaux de gris:

$$\text{PLPFr} = \frac{1}{T_R} \sum_{i=0}^{N_g-1} \sum_{j=1}^{N_r} i^2 r(i, j | \theta). \quad (4.25)$$

Dans le cadre de cette méthode, WESZKA, DYER et ROSENFELD (1976) remarquent que:

- Une texture rugueuse contiendra plus de plages relativement longues.
- Une texture fine contiendra des longueurs de plage plus courtes que celles d’une texture rugueuse.
- Dans une texture dite directionnelle, la plage apparaissant le long d’une ligne donnée dépendra entièrement de la direction de la ligne.

Il semble évident que la méthode des longueurs de plage produira de meilleurs résultats que les matrices de cooccurrences sur des textures contenant des formes plus allongées dans une direction ou une autre, mais elle sera moins efficace sur des textures aléatoires, et donc, sur des images médicales. Certains jugent cette méthode moins efficace que la méthode des matrices de cooccurrences (CONNERS et HARLOW 1980). Par contre, GALLOWAY (1975) obtient de très bons résultats lors de la classification d’images de terrains, en utilisant les attributs calculés à partir des matrices de longueurs de plage.

4.2 Méthodes spectrales ou d’analyse fréquentielle

Cette section est consacrée à la revue des trois méthodes de bases utilisées en analyse fréquentielle. La méthode de *la transformée de Fourier* est la méthode classique grâce à laquelle on peut séparer une image en bandes de fréquences spatiales. Elle présente cependant l’inconvénient de ne pas tenir compte de l’information locale dans une image, car il est impossible d’associer les points situés dans une bande de fré-

quence à une région de l'image analysée. Une solution est d'utiliser *la méthode des filtres de Gabor* ou *la transformée en ondelettes*, qui permettent d'effectuer des mesures de fréquences tout en conservant l'information locale.

4.2.1 L'énergie des textures par la transformée de Fourier

Afin d'analyser les variations spatiales de la fonction de l'image $I(x,y)$, il est bon de décomposer cette fonction sur une base de fonctions orthogonales (POSTAIRE 1987). La transformée de Fourier $F(u,v)$ de la fonction $f(x,y)$ est définie comme :

$$F(u,v) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x,y) \exp(-2\pi j(ux + vy)) dx dy \quad (4.26)$$

où j est un nombre complexe tel que $j^2 = -1$. Cette formule permet de passer d'une représentation de l'image $f(x,y)$ dans le domaine spatial à coordonnées x et y , à une représentation dans le domaine fréquentiel de variables u et v . S'il nous est permis de connaître $F(u,v)$, il est alors possible de calculer la fonction image en nous basant sur la transformée de Fourier inverse :

$$f(x,y) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} F(u,v) \exp(2\pi j(ux + vy)) du dv. \quad (4.27)$$

Notons que le spectre de puissance est défini comme :

$$|F|^2 = FF^*,$$

où F^* est la conjuguée complexe de F . Si l'on découpe le domaine de la transformée de Fourier en couronnes concentriques ou en secteurs angulaires (voir schéma 4.1), on peut caractériser une texture en calculant l'énergie de la texture dans chacun de ces deux domaines.

D'après WESZKA, DYER et ROSENFELD (1976), la distribution radiale des valeurs dans $|F|^2$ est sensible à la rugosité de la texture dans f : pour une texture fine et gra-




FIG. 4.1 – Partitionnement (a) radial et (b) angulaire de l'espace de la transformée de Fourier—Tirées de (Burrill 1997)

nuleuse dans laquelle les variations de niveaux de gris sont brutales et rapprochées, le spectre de Fourier présentera de fortes amplitudes dans le domaine de hautes fréquences. Les attributs Φ_r correspondant aux couronnes des grands rayons, seront donc prépondérants (POSTAIRE 1987).

Par contre, pour une texture grossière, avec des variations des niveaux de gris douces, le spectre de Fourier présentera de fortes amplitudes dans le domaine des basses fréquences. Dans ce cas, les attributs Φ_r associés aux couronnes de petits rayons, seront prépondérants (POSTAIRE 1987). L'analyse de la rugosité d'une texture implique donc de calculer l'ensemble d'attributs :

$$\Phi_r = \int_0^{2\pi} |F(r, \theta)|^2 d\theta, \quad (4.28)$$

pour différentes valeurs de r , le rayon de la couronne.

D'après WESZKA, DYER et ROSENFELD (1976), la distribution angulaire des valeurs dans $|F|^2$ est sensible à l'orientation de la texture dans f . Lorsqu'une texture présente une organisation directionnelle (lorsqu'elle est composée de plusieurs lignes ou arêtes dans la direction d'un angle θ) alors, les plus importantes variations des niveaux de gris apparaissent dans la direction perpendiculaire aux lignes d'orientation préférentielle (c'est-à-dire la direction $\theta + 2\pi$). Dans ce cas, $|F|^2$ présente de fortes

amplitudes dans la direction autour de laquelle les attributs Φ_θ sont prépondérants (POSTAIRE 1987), tandis que dans une texture non orientée, $|F|^2$ ne sera pas orienté non plus (WESZKA, DYER et ROSENFELD 1976). Ceci suggère qu'un excellent ensemble d'attributs permettant d'analyser l'orientation de la texture est fourni par :

$$\Phi_\theta = \int_0^\infty |F(r,\theta)|^2 dr, \quad (4.29)$$

pour différentes valeurs de θ .

Dans le cas d'une image numérique de dimension $n \times m$, sa représentation dans le domaine fréquentiel est calculée à l'aide de la transformée de Fourier discrète:

$$F(u,v) = \frac{1}{nm} \sum_{i=0}^{n-1} \sum_{j=0}^{m-1} f(x,y) \exp(-2\pi j(\frac{i}{n}u + \frac{j}{m}v)), \quad (4.30)$$

tandis que l'expression de la transformée de Fourier discrète inverse est définie comme :

$$f(x,y) = \sum_{u=0}^{n-1} \sum_{v=0}^{m-1} F(u,v) \exp(2\pi j(\frac{i}{n}u + \frac{j}{m}v)). \quad (4.31)$$

Cette formule indique qu'en tout point de l'image, le niveau de gris peut être exprimé par une somme pondérée de fonctions exponentielles complexes ayant différentes fréquences spatiales. L'ensemble d'attributs de texture standards associés à la transformée de Fourier discrète est fourni par :

$$\Phi_{r_1 r_2} = \sum_{\substack{r_1^2 \leq u^2 + v^2 < r_2^2 \\ 0 \leq u, 0 \leq v}} |F(u,v)|^2. \quad (4.32)$$

Cet ensemble d'attributs est associé à la couronne de rayon intérieur r_1 et de rayon extérieur r_2 . Un ensemble d'attributs associé au secteur angulaire compris entre les

angles θ_1 et θ_2 est fourni par :

$$\Phi_{\theta_1, \theta_2} = \sum_{\substack{\theta_1 \leq \arctan(\frac{u}{v}) < \theta_2 \\ 0 \leq u, 0 \leq v}} |F(u, v)|^2. \quad (4.33)$$

Ces attributs standards sont sensibles soit à la taille (fréquence spatiale), soit à l'orientation, mais pas aux deux à la fois, comme c'est le cas pour les attributs calculés pour les matrices de cooccurrences et la méthode des différences des niveaux de gris.

4.2.2 La méthode des filtres de Gabor

Le but de cette méthode est de combiner un filtrage fréquentiel avec une fenêtre de localisation spatiale. Soit l'équation de la gaussienne :

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{1}{2} \left[\left(\frac{x}{\sigma_x}\right)^2 + \left(\frac{y}{\sigma_y}\right)^2 \right]\right). \quad (4.34)$$

La fonction de Gabor $h(x, y)$ est une gaussienne modulée par une sinusoïde complexe de la forme :

$$h(x, y) = G(x \cos \theta + y \sin \theta, -x \sin \theta + y \cos \theta) \exp(j2\pi(ux + vy)). \quad (4.35)$$

Ainsi, nous obtenons le filtre :

$$m(x, y) = |I(x, y) * h(x, y)|. \quad (4.36)$$

Notons que h est la réponse impulsionnelle d'un filtre passe-bande centré sur la fréquence (u, v) et $I(x, y)$ est la fonction de l'image 2D. Le filtre est sélectif en orientation et en position.

Si la texture est composée d'éléments texturaux (aussi appelés *texels*), il sera alors possible de différencier des textures grâce à la nature des texels et de même que par leur orientation. En appliquant un banc de filtres à l'image et en calculant le module

carré du résultat du filtre complexe, on obtient une estimation du spectre local pour chaque position de l'image d'entrée. Définissant ce filtre dans un système de coordonnées polaires, sa fonction de transfert sera de la forme :

$$G_{ij}(\omega_r, \omega_\varphi) = \exp\left(\frac{(\omega_r - \omega_{ri})}{2\sigma_{ri}^2}\right) \exp\left(\frac{(\omega_\varphi - \omega_{\varphi j})}{2\sigma_{\varphi j}^2}\right), 1 \leq i \leq M \text{ et } 1 \leq j \leq N, \quad (4.37)$$

où M représente les bandes de fréquences et N , les orientations. En variant les valeurs de M et N , on obtient différentes valeurs de G_{ij} . Pour $M = 5$ et $N = 2$, par exemple, on obtient $G_{11}, G_{12}, \dots, G_{51}, G_{52}$ et le filtrage par ces différentes valeurs correspond alors aux attributs de la texture.

4.2.3 La transformée en ondelettes

L'application de la transformée en ondelettes au traitement d'image a été suggérée pour la première fois par MALLAT (1989). Celui-ci démontra que cette transformation peut être utilisée pour calculer la dimension fractale d'une image. KARAYIANNIS et STOURAITIS (1995) utilisèrent cette transformée afin de décomposer une image originale en sous-images et ce, afin d'effectuer la classification des textures en utilisant la dimension fractale. STOLLNITZ, DEROSE et SALESIN (1995), quant à eux, l'utilisèrent à des fins de compression d'images.

Si les filtres de Gabor effectuent un fenêtrage de l'information spatiale pour une bande de fréquences donnée, la transformée en ondelettes utilise, afin de filtrer l'image, la «fonction analysante» suivante :

$$\Psi_{a,b}(x) = |a|^{-\frac{1}{2}} \Psi\left(\frac{x-b}{a}\right) \quad (4.38)$$

où a est un paramètre d'échelle et b est un paramètre de translation. Notons que plus a est grand, plus la fonction s'élargit et plus a est petit, plus la fonction est localisée autour de x . Nous en concluons que la transformée en ondelettes est une méthode d'analyse multirésolution. Par exemple, MARR et HILDRETH (1980) ont proposé la

fonction analysante suivante :

$$\Psi_x = (|x|^2 - 2) \exp\left(\frac{-|x|^2}{2}\right), \text{ où } x \in \mathcal{R}^2. \quad (4.39)$$

Cette fonction, aussi appelée *chapeau mexicain* du fait de sa forme, permet une excellente localisation spatiale. Des mesures de covariance dans quatre directions sur les images issues de la transformation par quatre niveaux d'ondelettes permettent une bonne localisation de la frontière entre les textures.

4.3 L'approche basée sur la modélisation des textures

Nous avons plus haut décrit la texture comme une image possédant des attributs tels que la rugosité, la régularité, l'orientation, etc. L'objectif de l'approche basée sur la modélisation des textures est d'ajuster un modèle à une image texturée et de reconnaître ses caractéristiques dans un nombre limité d'attributs. Les modèles de textures basés sur les champs aléatoires sont probablement les meilleurs ; on les retrouve en compression, restauration (GEMAN et GEMAN 1984), segmentation (DERIN, ELLIOTT, CRISTI et GEMAN 1984) et (DERIN et ELLIOTT 1987), classification (MODESTINO, FRIES et VICKERS 1981) et synthèse de textures (CROSS et JAIN 1983). Le modèle des champs de Markov aléatoires (CMA) est un modèle très naturel de la texture, car il est capable de traduire de l'information locale dans un modèle global (DUBES et JAIN 1989), tandis que les champs de Gibbs aléatoires (CGA) décrivent les propriétés d'une image en termes de distributions conjointes des couleurs (niveaux de gris) de tous les pixels présents dans l'image.

Le modèle des champs de Markov aléatoires pour les textures assume que le champ de la texture est stochastique et stationnaire et satisfait à des hypothèses d'indépendance conditionnelle (HARALICK et SHAPIRO 1992). Nous savons que le niveau de gris d'un pixel d'une image est dépendant du niveau de gris du pixel voisin à moins que l'image en question ne soit que du bruit aléatoire. Dans cette section, nous définissons

deux modèles précis de cette indépendance, les modèles des champs de Markov et de Gibbs aléatoires¹³.

Petit historique

L'étude des champs de Markov aléatoires a vu le jour en 1925 avec la thèse d'Ising (ISING 1924) dans le domaine de la mécanique statistique afin de modéliser des interactions moléculaires au sein des matériaux ferromagnétiques (DERIN et ELLIOTT 1987). Le modèle CMA a été appliqué dans le cas de variables gaussiennes et binaires dans un treillis¹⁴. BESAG (1974) a adapté l'utilisation de ce modèle à des variables entières, de même qu'à des variables bornées et non bornées. Cette extension, associée à des procédures d'estimations, permet l'application des champs de Markov aléatoires à la modélisation des textures. Dans (HASSNER et SKLANSKY 1980), nous retrouvons l'exposé des équivalences existant entre l'expression de la probabilité conditionnelle dans le cas des champs de Gibbs et les champs de Markov aléatoires. Dans ce même contexte, BESAG (1974) démontra qu'un champ de Gibbs aléatoire unique existe pour chaque CMA et vice versa, et ce, tant que le CGA est défini en termes de cliques dans un système de voisinage.

Définitions générales

Définition 1: En nous limitant au seul cas de champs aléatoires et discrets 2D, on définit un *treillis* L de points (pixels) rectangulaire et de dimensions $N \times N$ comme :

$$L = \{(i,j) : 1 \leq i \leq N, 1 \leq j \leq N\}. \quad (4.40)$$

13. Cette section est basée sur les articles de CROSS et JAIN (1983), DERIN, ELLIOTT, CRISTI et GEMAN (1984), DERIN et ELLIOTT (1987) ainsi que de DUBES et JAIN (1989).

14. Lattice

Définition 2: Un système de voisinage η dans L est une collection de sous-ensembles de L ,

$$\eta = \{\eta_{ij} : (i,j) \in L, \eta_{ij} \subseteq L\}, \quad (4.41)$$

si, et seulement si η_{ij} le voisinage du pixel (i,j) est tel que (a) $(i,j) \notin \eta_{ij}$, et (b) si $(k,l) \in \eta_{ij}$, alors $(i,j) \in \eta_{kl}$ pour tout $(i,j) \in L$.

Les séquences hiérarchiquement ordonnées de systèmes de voisinage les plus souvent utilisées en modélisation d'images sont $\eta^1, \eta^2, \eta^3, \eta^4, \dots$, où $\eta^1 = \{\eta_{ij}^1\}$ est constituée des quatre voisins les plus proches de chaque pixel, et $\eta^2 = \{\eta_{ij}^2\}$, constituée des huit pixels voisins de (i,j) . Les structures du système de voisinage pour $\eta^1, \eta^2, \eta^3, \eta^4$ et η^5 sont représentées au schéma 4.2.




FIG. 4.2 – Les structures du système de voisinage η^m —Tirée de (Derin et Elliott 1987)

Définition 3: Mathématiquement, on définit une *clique* c d'une paire (L, η) comme un sous-ensemble de L tel que :

- a) c est constitué d'un pixel unique, ou
- b) Pour $(i, j) \neq (k, l), (i, j) \in c$ et $(k, l) \in c$ implique que $(k, l) \in \eta_{ij}$

L'ensemble de tous les cliques du type (L, η) est décrit comme $C = C(L, \eta)$. Les types de cliques associés à η^1 et η^2 sont représentés au schéma 4.3.

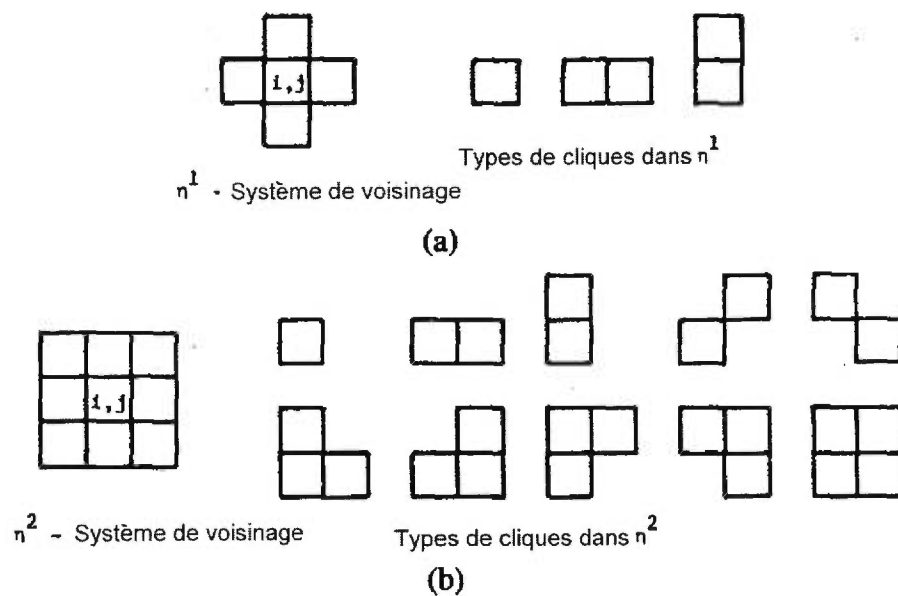


FIG. 4.3 – Les types de cliques associés aux systèmes de voisinages η^1 et η^2 —Tirée de (Derin et Elliott 1987)

Munis de ces définitions, nous pouvons à présent procéder à la définition d'un champ de Markov aléatoire.

Champs de Markov et Gibbs aléatoires

Soit $X(i,j)$, le niveau de gris au point (i,j) dans le treillis L de dimension $N \times N$. Nous simplifions en utilisant $X(i)$ au lieu de $X(i,j)$, $i = 1, 2, \dots, M$ où $M = N^2$.

Définition 1: Soit L , un treillis. Un *coloriage* de L est défini par la fonction $\mathbf{X} : L \mapsto \{0, 1, \dots, G - 1\}$.

Définition 2: Le point j est défini comme le *voisin* de i si $p(X(i)|X(1), X(2), \dots, X(i-1), X(i+2), \dots, X(M))$ dépend de $X(j)$. Notons que cette définition n'implique pas que le voisin d'un point donné est nécessairement proche de lui en terme de distance.

Définition 3: Le champ de Markov aléatoire est une densité de probabilité conjointe sur un ensemble de tous les coloriages \mathbf{X} possibles du treillis L , sujet aux conditions suivantes:

- (a) *Positivité* : $p(\mathbf{X}) > 0$ pour toutes les valeurs de \mathbf{X} .
- (b) *Markovianité* : $p(X(i)|\text{tous les points dans le treillis } \neq i) = p(X(i)|\text{les voisins de } i)$.
- (c) *Homogénéité* : $p(X(i)|\text{voisins de } i)$ est indépendante de i et ne dépend que de la configuration de ses voisins.

Dans le domaine de la modélisation et analyse des textures, un vif intérêt est porté non seulement aux CMA mais aussi aux CGA, et ce, suite au *théorème de Hammersley-Clifford*. Celui-ci établissait en 1970 l'existence d'une fonction bijective des CMA aux CGA. Il a été également démontré que la probabilité conjointe de CGA est plus exploitable que celle des CMA. Les détails de l'équivalence CMA-CGA peuvent être retrouvés dans l'article (BESAG 1974).

Dans un domaine spatial où le CMA est défini sur un treillis 2D, la théorie des CGA annonce que la probabilité d'un treillis ayant un état particulier est définie comme :

$$P(X = x) = \frac{1}{Z} \exp(-U(x)), \quad (4.42)$$

où X représente le vecteur des variables aléatoires des «couleurs» (niveaux de gris) dans l'image, x , l'état du treillis (image), $Z = \sum_x \exp(-U(x))$, la fonction de partition (une constante de normalisation), et la fonction d'énergie U est définie comme $U(x) = \sum_{c \in C} V_c(x)$, où $V_c(x)$ est la fonction de potentiel associée à la clique c .

Notons que chaque type de clique (voir le schéma 4.3) est associé à une fonction de potentiel $V_c(\cdot)$. Ainsi, pour un voisinage donné large, l'ensemble des fonctions de potentiel forme un modèle complet de texture. Les paramètres de ce modèle sont les valeurs potentielles associées à chaque type de clique (SMITH 1998). Mais en pratique, chaque texture exige un large système de voisinages et un grand nombre de niveaux de gris, et donc, un nombre élevé de types de cliques. Le nombre des fonctions de potentiel grandit donc très rapidement avec le nombre des niveaux de gris, et, dans ce cas, déterminer l'ensemble des paramètres nécessaires à la modélisation des textures devient une tâche impossible. Le problème réside également dans le fait que les niveaux de gris dans une image sont considérés comme des variables discrètes, ainsi que l'exige la formulation des CMA. L'ordre des niveaux de gris n'étant pas exploité dans les formulations des CMA, HASSNER et SKLANSKY (1980) ont proposé le modèle des champs de Markov et de Gibbs aléatoires (CMGA). C'est également pour cette raison que HASSNER et SKLANSKY (1980) ont proposé plusieurs simplifications, dans le but de réduire le nombre de paramètres : si la texture est considérée comme ayant une symétrie circulaire, le nombre de paramètres du modèle sera considérablement réduit. Ils ont aussi suggéré aussi que chaque fonction de potentiel n'ait que deux valeurs :

$$V_c(x) = \begin{cases} -\theta, & \text{si tous les pixels dans } c \text{ sont de même intensité,} \\ +\theta, & \text{autrement,} \end{cases}$$

où θ est un paramètre associé au type du clique c . Ce modèle est également appelé *modèle des CMA à cliques uniformes*¹⁵.

15. *Uniform-clique MRFs*

4.4 Méthodes structurelles

L'approche structurelle décrit une texture à l'aide de primitives et de lois de placements appropriées. Les textures simples peuvent être utilisées afin de créer des motifs texturaux plus complexes, en les faisant répéter et varier en orientation et dimension. L'approche structurelle a pour but de reconnaître les primitives dans une texture inconnue et de déterminer les lois de placement, afin de caractériser la texture. Bien que cette méthode soit importante, son utilisation reste très limitée en analyse d'images médicales, car les textures biomédicales tendent à être de nature statistique. Dans les cas des images SPECT de cerveaux, par exemple, la texture s'avère être de type aléatoire, car le bruit ambiant lors de l'acquisition des images est très fort. De plus, le cerveau est constitué de tissus mous et ne contient aucune zone texturée structurelle. Aussi, il n'y a aucune primitive dans les matières blanche et grise du cerveau. Cette approche sera détaillée au chapitre 5, consacrée aux méthodes de classification.

4.5 Méthodes fractales

Les fractales sont des figures géométriques de structure complexe dont la création ou la forme met en jeu des règles utilisant le fractionnement. Les fractales sont à la base d'un nouveau système de géométrie permettant de représenter des objets très irréguliers tels que les reliefs montagneux, les amas galactiques ou les côtes rocheuses très découpées. Apparues au XIX^e siècle, les fractales sont considérées comme des curiosités mathématiques jusqu'au XX^e siècle. Elles n'acquièrent un statut à part entière que dans les années 70, grâce au mathématicien français Benoît Mandelbrot qui en fit l'objet d'une nouvelle discipline mathématique: *la géométrie fractale*. Le mot Fractale, du latin *fractus*, qui veut dire *brisé*, a été inventé par Mandelbrot pour désigner un type d'objets dont l'irrégularité les distingue des figures géométriques euclidiennes, tels que la droite ou le cercle. En géométrie euclidienne, les figures ont des dimensions entières: 0, pour le point; 1, pour une courbe; 2, pour une surface et 3, pour un

volume. La dimension d'une fractale (DF) peut en revanche prendre des valeurs qui ne sont pas des nombres entiers et constituer ainsi une généralisation de la notion de dimension utilisée en géométrie euclidienne. La géométrie fractale n'est pas qu'une théorie abstraite. En effet, les fractales se sont révélées adaptées à la représentation d'objets naturels complexes: montagnes, nuages, poumons, etc. Elles interviennent également dans le cadre de *la théorie du chaos déterministe*¹⁶, qui possède des applications dans de nombreux domaines telles la chimie, la mécanique des fluides et la biologie. Par ailleurs, la beauté des fractales en a fait un élément clé de l'infographie. Les fractales servent aussi à charger des images fixes ou des vidéos sur ordinateurs. En 1987, le mathématicien Michel F. Barnsley montra qu'il est possible d'obtenir une approximation de photographies numérisées à l'aide de fractales. Par ce moyen, il est possible de stocker des images en utilisant un nombre minimal de données. Cette compression fractale des images est utilisée dans de nombreuses applications multimédias. Aussi, plusieurs publications en traitement d'images démontrent l'utilité des fractales: PENTLAND (1984 ; 1986) développa un modèle fractal 3D utilisé en segmentation et classification des textures. KARAYIANNIS et STOURAITIS (1995) utilisèrent la DF afin de classifier des textures présent sur des images décomposées. RIGAUT (1988) quant à lui, utilisa la DF pour la segmentation d'images.

4.5.1 La dimension fractale (DF)

MANDELBROT (1982) fut le premier à décrire une approche efficace au calcul de la dimension fractale, lorsqu'il essaya d'estimer la longueur d'une courbe formée par les côtes du littoral¹⁷. Il considéra tous les points situés de part et d'autre de la courbe de la côte à une distance inférieure ou égale à ε . Ainsi, il suggéra que les points en question forment une bande de largeur 2ε , et supposa que la longueur de la ligne

16. *La théorie du chaos déterministe est une théorie qui s'applique aux systèmes dont les comportements sont imprévisibles, bien que leurs composantes soient gouvernées par des lois strictement déterministes.*

17. *Cette section est tirée de (REUZÉ 1995) et de (SARKAR et CHAUDHURI 1992).*

de côte $l(\varepsilon)$ est égale à la surface de la bande divisée par 2ε . Sachant que, lorsque la valeur d' ε diminue, la valeur de $l(\varepsilon)$ augmente, il étudia plusieurs lignes de côte, et détermina que la formule la plus appropriée était:

$$l(\varepsilon) = F\varepsilon^{(1-D)},$$

où F et D sont des constantes associées à chaque ligne de côte spécifique. Il nomma la constante D la *dimension fractale*. En prenant l'approximation linéaire par moindres carrés de la représentation graphique log-log de la courbe de $l(\varepsilon)$ et ε , il est possible de déterminer D . Si m est la pente de cette droite, alors la DF de la courbe (ligne de côte) sera égale à $1 - m$. Sachant que m sera toujours négative, la DF ainsi calculée ne fournit que de l'information globale sur l'image analysée et n'est suffisante que pour un objet fractal idéal et entièrement autosimilaire.

4.5.2 Les approches utilisées pour estimer la DF d'une image

Plusieurs méthodes d'estimation de la DF sont proposées dans la littérature. Les plus utilisées sont décrites dans cette section.

La méthode de Peleg

PELEG, NAOR, HARTLEY et AVNIR (1984) utilisèrent l'idée de Mandelbrot pour le calcul de l'aire d'une surface. Ils mesurèrent une surface d'une image constituée de niveaux de gris (où la hauteur de la surface de l'image est proportionnelle aux niveaux de gris). Donc, tous les points situés à une distance ε de part et d'autre de la surface forment une «couverture» d'épaisseur 2ε . Pour différentes valeurs d' ε , l'air de la «couverture» est alors estimée itérativement comme suit. La couverture en question est définie par ses deux surfaces, inférieure (u_ε) et supérieure (b_ε). Connaissant la fonction de l'image $I(i,j)$, nous avons $u_0(i,j) = b_0(i,j) = I(i,j)$. Pour $\varepsilon = 1, 2, \dots$, les surfaces de la «couverture» sont définies comme suit:

$$u_\varepsilon(i,j) = \min\{u_{\varepsilon-1}(i,j) + 1, \max_{d(i,j,m,n) \leq 1} u_{\varepsilon-1}(m,n)\}, \quad (4.43)$$

$$b_\varepsilon(i,j) = \min\{b_{\varepsilon-1}(i,j) - 1, \min_{d(i,j,m,n) \leq 1} b_{\varepsilon-1}(m,n)\}. \quad (4.44)$$

où $d(i,j,m,n)$ est la distance entre les pixels (i,j) et (m,n) . Le volume de la couverture (le volume situé entre les deux surfaces) est donné par:

$$v_\varepsilon = \sum_{i,j} (u_\varepsilon(i,j) - b_\varepsilon(i,j)), \quad (4.45)$$

tandis que l'aire de la surface est définie comme:

$$A(\varepsilon) = \frac{(v_\varepsilon - v_{\varepsilon-1})}{2}. \quad (4.46)$$

La DF de la surface s'obtient à partir de la relation:

$$A(\varepsilon) = F\varepsilon^{(2-D)}. \quad (4.47)$$

En prenant l'approximation linéaire par moindres carrés de la représentation graphique du log-log de la courbe de $A(\varepsilon)$ et ε , il est alors possible de déterminer D .

La méthode basée sur la transformée de Fourier

PENTLAND (1984) utilisa le spectre de Fourier de la surface des intensités d'une image afin de calculer la DF. Il peut être démontré que le spectre de puissance de Fourier $P(f)$ de la fonction fractale Brownienne (f) est proportionnel à f^{-2h-1} , où $h = 2 - D$. En prenant l'approximation linéaire par moindres carrés de la représentation

graphique du log-log de la courbe de $P(f)$ et f , il est possible de déterminer la DF de la surface des intensités d'une image.

La méthode des boîtes

En analyse d'images médicales, cette méthode est l'une des plus utilisées et a pour but de calculer la DF d'une surface ainsi qu'un autre paramètre, la lacunarité λ . Ainsi, la méthode des fractales ne s'applique que sur des surfaces analysées qui sont *autosimilaires*.

L'autosimilarité: Soit un segment A de longueur 1 (par exemple), composé de N_r segments de longueurs $r = \frac{1}{N_r}$. Chaque sous-segment est la réduction du segment initial par le facteur $\frac{1}{N_r}$. On dit alors que le segment A possède la propriété d'autosimilarité, d'où la relation:

$$N_r r^1 = 1, \text{ pour un segment.}$$

En généralisant à une dimension quelconque on obtient:

$$N_r r^D = 1.$$

La DF peut alors être déduite de l'équation :

$$D = \frac{\log(N_r)}{\log(\frac{1}{r})}. \quad (4.48)$$

D est donc la valeur qui fait que, quelle que soit la longueur r de l'étalon choisi, on obtient toujours la même mesure lorsqu'on multiplie cet étalon par le nombre de fois qu'il est contenu dans l'objet (REUZÉ 1995).

Calcul de la DF: Soit une image constituée de $M \times M$ pixels, considérée comme une surface tridimensionnelle (x,y,z) où (x,y) est la position du pixel dans l'image et z est l'intensité (niveau de gris) de ce pixel. Si l'on départage l'espace (x,y) en grilles de taille $s \times s$ pixels tel que: $r = \frac{s}{M}$, alors, à chaque position de la grille, on place une

colonne verticale composée de cubes (boîtes), chacune ayant la dimension $s \times s \times s$ (voir schéma 4.4).




FIG. 4.4 – Détermination de n_r par la méthode des boîtes—Tirée de (Sarkar et Chaudhuri 1992)

On numérote ensuite ces boîtes séquentiellement de 1 jusqu'à la boîte qui contient le plus haut niveau de gris dans cette grille, si les niveaux de gris maximum et minimum dans la (i, j) -ème grille de l'image se trouvent dans les boîtes k et l respectivement, alors la contribution de N_r dans la (i, j) -ème grille est donnée par:

$$n_r = l - k + 1. \quad (4.49)$$

N_r est estimée en calculant la somme de tous les n_r dans l'image:

$$N_r = \sum_{i,j} n_r(i,j), \quad (4.50)$$

où N_r est calculée pour différentes valeurs de r (c'est-à-dire différentes valeurs de s). Ainsi, en utilisant les équations 4.49, 4.50 et 4.48, on peut estimer la DF (qui sera utilisée comme attribut de la texture).

Mais la DF seule, utilisée comme attribut de texture, n'est pas suffisante afin de caractériser une texture. Plusieurs chercheurs cités dans (SMITH 1998) ont montré des exemples de textures très différentes mais de même dimension fractale. C'est pour cette raison qu'en analyse de texture, il est préférable d'ajouter le paramètre de lacunarité.

Lacunarité d'un objet fractal : Le paramètre λ permet de distinguer deux objets fractals de même dimension fractale mais d'aspect et de texture différents. Ce paramètre prend en considération la distribution de $P(m,L)$, la probabilité qu'il y ait m points dans une boîte de taille L . Soit $M(L)$ et $M_2(L)$, les moments de degrés 1 et 2 de $P(m,L)$:

$$M(L) = \sum_m mP(m,L) \quad (4.51)$$

$$M_2(L) = \sum_m m^2P(m,L). \quad (4.52)$$

La lacunarité est alors calculée comme suit:

$$\lambda = \frac{M_2(L) - (M(L))^2}{(M(L))^2} \quad (4.53)$$

Ce paramètre est caractéristique de la rugosité de la texture. Si cette dernière est fine, alors la valeur de λ sera faible. Par contre, si elle est rugueuse, la lacunarité sera importante.

Maintenant que nous avons fait un survol détaillé des différentes méthodes permettant l'acquisition des attributs de la texture, nous allons voir en détail dans le chapitre suivant les différentes méthodes de classification.

Chapitre 5

Les méthodes de classification

5.1 Introduction

Les procédures de classification sont à la base de nombreuses techniques d'analyse d'images. Elles constituent l'un des fondements des méthodes de reconnaissance des formes. Le point de départ de ces procédures est la représentation des observations multidimensionnelles associées aux entités sur lesquelles on aura mesuré et calculé différents attributs caractéristiques. Les étapes d'analyses de textures étant décrites en détail dans le chapitre 3, nous nous limiterons dans celui-ci à la description des différentes méthodes de classification, qui constituent la cinquième étape en analyse de texture.

D'après (GONZALEZ et WOODS 1992), il existe deux approches fondamentales pour résoudre les problèmes de classement et de classification :

- a) **La théorie de la décision:** elle est basée sur la représentation de la texture sous forme de vecteur d'attributs et la détermination des approches appropriées afin de regrouper et d'assigner les vecteurs d'attributs à leurs classes respectives. Les méthodes principales utilisées par cette approche sont: *le classifieur de distance minimum, les corrélateurs, le classifieur de Bayes et les réseaux de neurones*. Notons que

les attributs de texture utilisés par cette approche ont été décrits dans le chapitre précédent et ils varient en fonction de la méthode d'analyse des textures choisie. Ces attributs forment alors un vecteur d'attributs dans l'espace des attributs.

- b) **L'approche structurelle:** le but de cette approche est de représenter la texture en format symbolique (chaîne ou arbre par exemple) le but étant d'associer la texture à des symboles précis.

Comme nous l'avons déjà mentionné à maintes reprises, les images qui nous intéressent dans le cadre de ce mémoire, sont des images SPECT médicales et donc du type aléatoire. Par conséquent, l'approche de classification structurelle s'avère être inadéquate pour notre problème¹.

5.2 Les méthodes basées sur la théorie de la décision

5.2.1 Les méthodes statistiques

La théorie de la décision constitue une approche statistique fondamentale pour résoudre les problèmes de classement et de classification (POSTAIRE 1987). En premier lieu, les méthodes statistiques sont basées sur l'estimation d'attributs simples afin d'évaluer les paramètres statistiques pour chaque classe. Dans le cas du *classifieur de distance minimum*, par exemple, le paramètre à estimer est le vecteur de moyenne de chaque classe. D'un autre côté, dans le cas du *classifieur de Bayes de distribution Gaussienne*, on estime deux paramètres statistiques: le vecteur de moyenne et la matrice de covariance pour chaque classe. Notons que les attributs utilisés pour le calcul de ces paramètres sont connus, et proviennent de classes connues. C'est pour cela que l'ensemble de ces attributs porte le nom *d'ensemble d'apprentissage*. Après que les paramètres aient été calculés, la structure du classifieur est alors fixée. On peut alors, en deuxième lieu, utiliser des fonctions de décisions. Le problème consiste à trou-

1. Les méthodes de classification décrites plus bas ont été tirées de (POSTAIRE 1987), (HAND 1981), (BISHOP 1995) et surtout de (GONZALEZ et WOODS 1992).

ver M fonctions discriminantes $d_1(X), d_2(X), \dots, d_M(X)$ chacune associée à une classe concrète, avec la probabilité que si le vecteur d'attributs X appartient à la classe C_j alors :

$$d_i(X) < d_j(X), \text{ pour } j = 1, 2, \dots, M; j \neq i. \quad (5.1)$$

X est l'observation, c'est-à-dire le vecteur d'attributs N -dimensionnel provenant d'objets à classer parmi les M classes notées $C_m : m : 1, 2, \dots, M$. La frontière de décision² qui sépare la classe C_i de la classe C_j est donnée par les valeurs d' X pour lesquelles $d_i(X) = d_j(X)$ ou, par la formule suivante :

$$d_i(X) - d_j(X) = 0. \quad (5.2)$$

En pratique, on identifie la frontière de décision entre deux classes en fonction du signe de la fonction suivante :

$$d_{ij}(X) = d_i(X) - d_j(X). \quad (5.3)$$

Dans un cas particulier, tel qu'un problème à deux classes comme le nôtre où il est question de déterminer à laquelle des deux classes, C_1 ou C_2 , appartient le vecteur d'attributs X , nous observerons le signe de la fonction $d_{12}(X) = d_1(X) - d_2(X)$. Si $d_{12}(X) > 0$, alors le vecteur d'attributs X appartient à la classe C_1 . Dans le cas échéant, si $d_{12}(X) < 0$, alors le vecteur d'attributs X appartient à la classe C_2 .

Voyons maintenant en détail les différentes méthodes de classifications statistiques.

Le classifieur de distance minimum

La distance séparant deux observations dans l'espace des attributs est une mesure naturelle de leur ressemblance. Il existe dans la littérature plusieurs méthodes de clas-

2. Decision boundary

sification faisant appel à ce concept géométrique. Le principe fondamental à retenir est que, d'une façon générale, les distances séparant les observations assignées à une même classe sont plus petites que celles séparant deux observations provenant de classes différentes (POSTAIRE 1987).

Supposons que chaque vecteur d'attributs est représenté par un vecteur dit *prototype* ou moyenne :

$$m_j = \frac{1}{N_j} \sum_{X \in C_j} X \quad j = 1, 2, \dots, M \quad (5.4)$$

où N_j est le nombre de vecteurs d'attributs de la classe C_j . Une façon de déterminer si un vecteur d'attributs X appartient à la classe C_j serait de calculer la distance euclidienne :

$$D_j(X) = \|X - m_j\| \quad j = 1, 2, \dots, M. \quad (5.5)$$

Si la valeur numérique de $D_j(X)$ est la plus petite en comparaison avec l'ensemble des distances euclidiennes $[D_m]$ avec $m : 1, 2, \dots, M$, on déduit alors que X appartient à la classe C_j . Ceci est équivalent à calculer la fonction de décision suivante :

$$d_j(X) = X^T m_j - \frac{1}{2} m_j^T m_j \quad j = 1, 2, \dots, M. \quad (5.6)$$

Nous assignerons le vecteur d'attributs X à la classe C_j si d_j a la plus grande valeur numérique. D'après les équations précédentes (5.2) et (5.6), il est clair que la formule mathématique de la frontière de décision entre les deux classes C_i et C_j pour le classifieur de distance minimum est :

$$\begin{aligned} d_{ij}(X) &= d_i(X) - d_j(X) \\ &= X^T (m_i - m_j) - \frac{1}{2} (m_i - m_j)^T (m_i - m_j) \\ &= 0. \end{aligned}$$

La surface qui résulte de cette équation est la bissectrice perpendiculaire au segment qui joint les deux points m_i et m_j . La méthode de classification basée sur les distances minimum fonctionne très bien lorsque la distance entre les moyennes est très grande en comparaison avec l'étalement de chaque classe. En d'autres termes, cette méthode est efficace pour des classes facilement séparables et donc où il y a peu de recouvrement.

Les corrélateurs

L'une des relations de la transformée de Fourier qui constitue un lien important entre le domaine spatial et le domaine fréquentiel est la *corrélation*. Cette relation a une importance fondamentale dans la compréhension des techniques de traitement d'images basées sur la transformée de Fourier. L'une des applications de la corrélation en traitement d'images est dans le domaine de *l'ajustement des prototypes*. Ceci s'explique comme suit : lorsqu'on a un problème qui consiste à trouver le meilleur ajustement possible entre une image inconnue et un ensemble d'images connues, on calcule les corrélations entre l'image inconnue et chacune des images connues. Le meilleur ajustement est alors trouvé en sélectionnant l'image qui a permis d'obtenir la plus grande valeur de la fonction de corrélation (GONZALEZ et WOODS 1992).

Application : nous allons utiliser ici le concept de la corrélation des images afin de trouver les ajustements possibles d'une sous-image $w(x,y)$ de taille $J \times K$ à une image $f(x,y)$ de taille $M \times N$ où $J \leq M$ et $K \leq N$. Bien que l'approche basée sur la corrélation peut être formulée sous forme de vecteur, travailler avec des images ou des sous-images directement est plus intuitif et plus traditionnel.

La fonction exprimant la corrélation entre l'image $f(x,y)$ et la sous-image $w(x,y)$ est décrite comme :

$$c(s,t) = \sum_x \sum_y f(x,y)w(x-s,y-t) \quad (5.7)$$

où $s = 0, 1, \dots, M - 1$ et $t = 0, 1, \dots, N - 1$. La sommation est faite sur la région de l'image où w et f se chevauchent (se recouvrent). Notons que pour une valeur quelconque de (s, t) à l'intérieur de $f(x, y)$, si l'on applique la fonction (5.7) on obtient une valeur unique de c . Par contre, si l'on varie s et t , $w(x, y)$ va se «promener» à l'intérieur de l'image $f(x, y)$ donnant la valeur de la fonction $c(s, t)$. La valeur maximum de $c(s, t)$ indique la position où $w(x, y)$ s'ajuste le mieux à $f(x, y)$.

La fonction de corrélation donnée par l'équation (5.7) a le désavantage d'être sensible aux amplitudes de $f(x, y)$ et $w(x, y)$. Afin d'y remédier, il est d'usage d'effectuer un ajustement via le *coefficient de corrélation* défini comme suit :

$$\rho(s, t) = \frac{\sum_x \sum_y [f(x, y) - \bar{f}(x, y)][w(x - s, y - t) - \bar{w}]}{\left\{ \sum_x \sum_y [f(x, y) - \bar{f}(x, y)]^2 \sum_x \sum_y [w(x - s, y - t) - \bar{w}]^2 \right\}^{\frac{1}{2}}} \quad (5.8)$$

où $s = 0, 1, \dots, M - 1$ et $t = 0, 1, \dots, N - 1$, \bar{w} est la valeur moyenne des pixels dans la sous-image $w(x, y)$, $\bar{f}(x, y)$ est la valeur moyenne de $f(x, y)$ dans la région qui coïncide avec la location courante de w . Les valeurs de $\rho(s, t)$ sont comprises entre -1 et 1. En procédant de la même façon qu'avec la fonction de corrélation, la valeur maximum de $\rho(s, t)$ est obtenue à la position où $w(x, y)$ s'ajuste le mieux à $f(x, y)$.

Pourtant, il est souvent plus simple de travailler dans le domaine des fréquences surtout si les deux images (originale et celle que l'on veut ajuster) ont les mêmes tailles. En utilisant la transformée de Fourier des deux images, l'image résultante G se calcule comme suit:

$$G = \frac{\mathcal{F}^{-1}(F.W^*)}{\{\mathcal{F}^{-1}(F.F^*)\mathcal{F}^{-1}(W.W^*)\}^{\frac{1}{2}}} \quad (5.9)$$

où \mathcal{F}^{-1} est la transformée de Fourier inverse, W^* , la conjuguée complexe de W , et F^* , celle de F , tandis que F et W sont les transformées de Fourier de f et w . L'opération «.» désigne une convolution.

Dans l'image résultante G , une région correspondant à l'endroit où w s'ajuste le mieux à f sera plus brillante que les autres (voir la série d'images de la figure 5.1).



FIG. 5.1 – *Image de gauche: Image originale. Image de centre: Image à ajuster. Image de droite: Résultat de la corrélation entre une l'image originale et l'image à ajuster dans le domaine des fréquences*

Les classifieurs statistiques optimaux

La théorie de la décision indique comment implanter une procédure de classement optimale à partir de la connaissance des fonctions de densité de probabilité conditionnelle $p(X/C_i)$ et des probabilités a priori $p(C_i)$ de chacune des classes C_i en présence.

Les attributs sont alors des grandeurs locales mesurées ou calculées sur l'image numérique au niveau de chacun de ces points. Nous assumons l'existence d'un modèle mathématique pour les fonctions de densité de probabilité des classes. L'approche paramétrique nous permet de faire l'hypothèse que les lois de distribution des vecteurs d'attributs suivent des modèles statistiques analytiques définis par quelques paramètres. Ici nous nous limiterons à des distributions normales. En effet, il existe un grand nombre de modèles intéressants pour décrire des distributions monovariées mais seule la loi normale s'avère réellement exploitable au niveau des manipulations mathématiques et utilisables du point de vue des calculs dès qu'on aborde des problèmes multivariés. Sous l'hypothèse normale, la méthode de classement paramétrique consiste à déterminer des paramètres du modèle analytique de la fonction de densité de chaque classe à partir des prototypes disponibles (POSTAIRE 1987).

Le classifieur de Bayes pour un modèle Gaussien : soit $X = (x_1, x_2, \dots, x_n)^T$, un vecteur d'attributs n-dimensionnel. Pour M classes d'attributs C_1, C_2, \dots, C_M , si un attribut X appartient à une classe C_i , alors :

$$d_i(X) < d_j(X) \quad j = 1, 2, \dots, M; \quad j \neq i. \quad (5.10)$$

Le classifieur de Bayes attribut X à une classe C_i si :

$$p(X/C_i)p(C_i) < p(X/C_j)p(C_j) \quad j = 1, 2, \dots, M; \quad j \neq i. \quad (5.11)$$

En nous référant aux équations (5.10) et (5.11), les fonctions de décisions auront les formes :

$$d_i(X) = p(X/C_i)p(C_i), \quad \text{pour la classe } C_i \quad (5.12)$$

$$d_j(X) = p(X/C_j)p(C_j), \quad \text{pour la classe } C_j. \quad (5.13)$$

Dans le cas n-dimensionnel, l'une des formes mathématiques les plus courantes attribuée à $p(X/C_i)$ est la fonction de probabilité Gaussienne suivante :

$$p(X/C_i) = \frac{1}{(2\pi)^{n/2} |S_i|^{1/2}} \exp \left[-\frac{1}{2} (x - m_i)^T S_i^{-1} (x - m_i) \right], \quad (5.14)$$

où m_i est le vecteur de la moyenne tel que :

$$m_i = E_i\{X\} = \frac{1}{N_i} \sum_{x \in C_i} X, \quad (5.15)$$

et S_i est la matrice de covariance telle que :

$$S_i = E_i\{(X - m_i)(X - m_i)^T\} = \frac{1}{N_i} \sum_{x \in C_i} X X^T - m_i m_i^T \quad (5.16)$$

où N_i est le nombre des vecteurs d'attributs de la classe C_i .

Nous avons vu plus haut que la fonction de décision de Bayes pour la classe C_i est $d_i(X) = p(X/C_i)p(C_i)$. Mais vue la forme exponentielle de la densité Gaussienne, travailler avec le logarithme naturel pour cette fonction de décision s'avère être plus simple. En d'autres termes, on peut travailler avec la forme suivante :

$$d_i(X) = \ln[p(X/C_i)p(C_i)] = \ln[p(X/C_i)] + \ln[p(C_i)]. \quad (5.17)$$

En nous basant sur l'équation (5.14), l'équation (5.17) aura la forme suivante :

$$d_i(X) = \ln[p(C_i)] - \frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |S_i| - \frac{1}{2} [(x - m_i)^T S_i^{-1} (x - m_i)]. \quad (5.18)$$

Mais comme $\frac{n}{2} \ln 2\pi$ est le même pour toutes les classes, nous pouvons l'éliminer de l'équation (5.18), ce qui nous donne :

$$d_i(X) = \ln[p(C_i)] - \frac{1}{2} \ln |S_i| - \frac{1}{2} [(x - m_i)^T S_i^{-1} (x - m_i)]. \quad (5.19)$$

L'équation (5.19) représente la fonction de décision de Bayes pour des classes d'attributs Gaussiens. Si toutes les matrices de covariances sont égales alors l'équation (5.19) aura la forme suivante :

$$d_i(X) = \ln[p(C_i)] + X^T S^{-1} m_i - \frac{1}{2} m_i^T S^{-1} m_i \quad (5.20)$$

qui représentera alors une fonction de décision linéaire. Si de plus, $S = I$, où I est une matrice identité et $p(C_i) = \frac{1}{M}$, pour $i = 1, 2, \dots, M$, alors :

$$d_i(X) = X^T m_i - \frac{1}{2} m_i^T m_i \quad (5.21)$$

L'équation (5.21) représente la fonction de décision pour le classifieur de distance minimum, tel que décrit plus haut.

5.2.2 Les réseaux de neurones

La base de cette méthode consiste dans l'utilisation d'une multitude d'éléments non linéaires nommés *neurones*, organisés en forme de réseaux et connectés un peu de la même façon qu'ils le sont dans notre cerveau. Le modèle résultant est connu sous le nom de *réseau de neurones*. Ces réseaux sont utilisés comme des véhicules afin de développer les coefficients de la fonction de décision via les représentations des ensembles d'apprentissage.

L'intérêt pour les réseaux de neurones commença dans les années 1940, par le travail de MCCULLOCH et PITTS (1943). Il proposèrent des modèles de neurones à seuil binaire et des algorithmes stochastiques capables d'introduire des changements d'état brusques (0-1 et 1-0) dans les neurones en les considérant comme la base de la modélisation des systèmes de neurones. Par la suite, HEBB (1949) proposa un travail basé sur des modèles mathématiques qui avaient pour but de capturer le concept de l'apprentissage à l'aide d'associations.

Dans le début des années 1960, ROSENBLATT (1962) introduisit une nouvelle classe d'algorithmes d'apprentissages qui ramena du nouveau dans le domaine de la théorie de la reconnaissance des formes. La raison pour laquelle un intérêt majeur fut porté à ce nouvel algorithme d'apprentissage, *le perceptron*, est qu'il fut montré, et ce grâce à des preuves mathématiques, que le perceptron, quand entraîné avec des ensembles d'apprentissages linéairement séparables, peut converger vers une solution, et ce, après un nombre fini d'itérations.

À la base, le perceptron est en mesure d'apprendre une fonction de décision linéaire, elle-même capable de séparer deux ensembles d'apprentissage linéairement séparables. La figure 5.2 montre l'architecture d'un modèle de perceptron pour deux classes d'attributs.

La réponse de cet appareil est une fonction de décision calculée en fonction : (1) des poids $w_i, i = 1, 2, \dots, n, n + 1$, qui ont pour fonction de modifier les entrées avant qu'elles

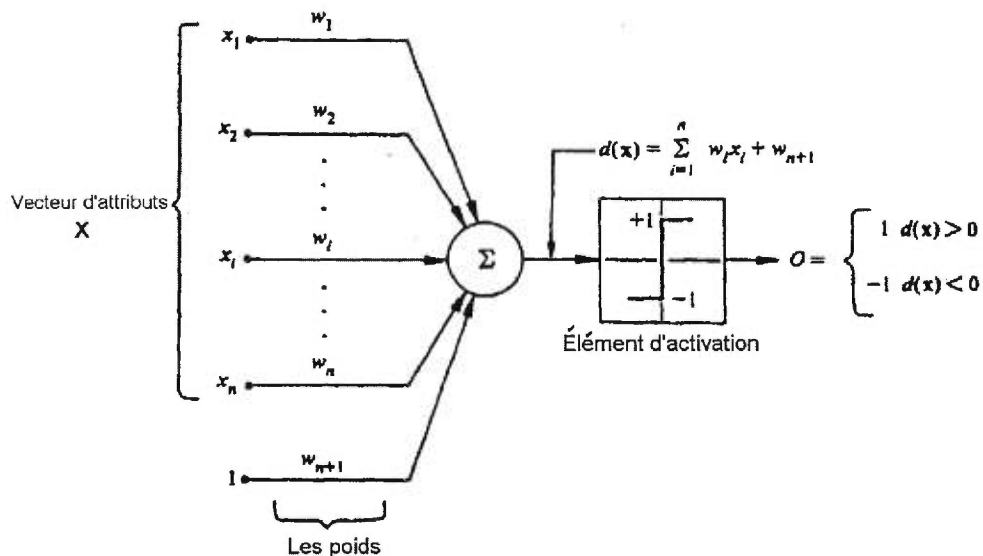


FIG. 5.2 – Architecture d'un modèle de perceptron pour deux classes d'attributs—Tirée de (Gonzalez et Woods 1992)

ne soient sommées et introduites dans l'élément de seuillage, et (2) des composantes des vecteurs d'attributs: $x_i, i = 1, 2, \dots, n$. La fonction de décision est alors calculée comme suit:

$$d(x) = \sum_{i=1}^n w_i x_i + w_{n+1}. \quad (5.22)$$

La sortie du système sera:

$$O = \begin{cases} +1 & \text{si } \sum_{i=1}^n w_i x_i > -w_{n+1}, \\ -1 & \text{si } \sum_{i=1}^n w_i x_i < -w_{n+1}. \end{cases} \quad (5.23)$$

Se référant à la figure 5.2, la fonction qui transforme les sorties de la jonction de sommation en sorties définitives du système est appelée *fonction d'activation*. Lorsque $d(x) > 0$, l'élément de seuillage fait en sorte qu'à la sortie du perceptron nous ayons une valeur égale à +1, indiquant ainsi que le vecteur d'attributs X appartient à la

classe C_1 . De même, si $d(x) < 0$, l'élément de seuillage donne à la sortie du perceptron une valeur égale à -1 , indiquant ainsi que le vecteur d'attributs X appartient à la classe C_2 . La frontière de décision résultante est calculée comme suit :

$$d(x) = \sum_{i=1}^n w_i x_i + w_{n+1} = 0 \quad (5.24)$$

ce qui nous donne l'équation d'un hyperplan. Géométriquement, les premiers n coefficients établissent l'orientation de l'hyperplan, tandis que w_{n+1} , est lié à la distance de l'origine jusqu'à l'hyperplan.

Il a été montré que ce perceptron de base ainsi que quelques-unes de ses généralisations sont inadéquates, quand appliqués à la majeure partie des problèmes pratiques de reconnaissances des formes, car dans la réalité, trouver deux classes linéairement séparables est chose très rare. Ainsi, les recherches se portèrent sur le développement de nouvelles techniques, capables cette fois-ci de séparer deux classes qui ne soient pas forcément linéairement séparables. C'est pour cela que RUMELHART, HINTON et WILLIAMS (1986), dans les années 1980 développèrent de nouveaux algorithmes d'apprentissage pour des perceptrons à multicouches. Leur méthode, *la règle delta généralisée pour l'apprentissage par rétropropagation* donna naissance à une méthode d'apprentissage efficace pour les systèmes à multicouches. Bien qu'il ne fut pas prouvé que cet algorithme pouvait converger à une solution optimale (comme ce fut le cas pour le perceptron), cette méthode s'avéra être efficace afin de résoudre différents problèmes pratiques. Et c'est à partir de ce moment que le perceptron à multicouches fut reconnu comme étant le modèle principal et le plus utilisé en réseaux de neurones.

La figure 5.3 montre la structure d'un réseau de neurones type. Il est composé de plusieurs couches, chacune composée de plusieurs neurones identiques arrangés de telle façon à ce que la sortie de chaque neurone dans l'une des couches, alimente l'entrée de chaque neurone de la couche suivante. Le nombre de neurones dans la première couche A , est $N_A = n$, quand n est la dimension du vecteur d'attributs d'entrée.

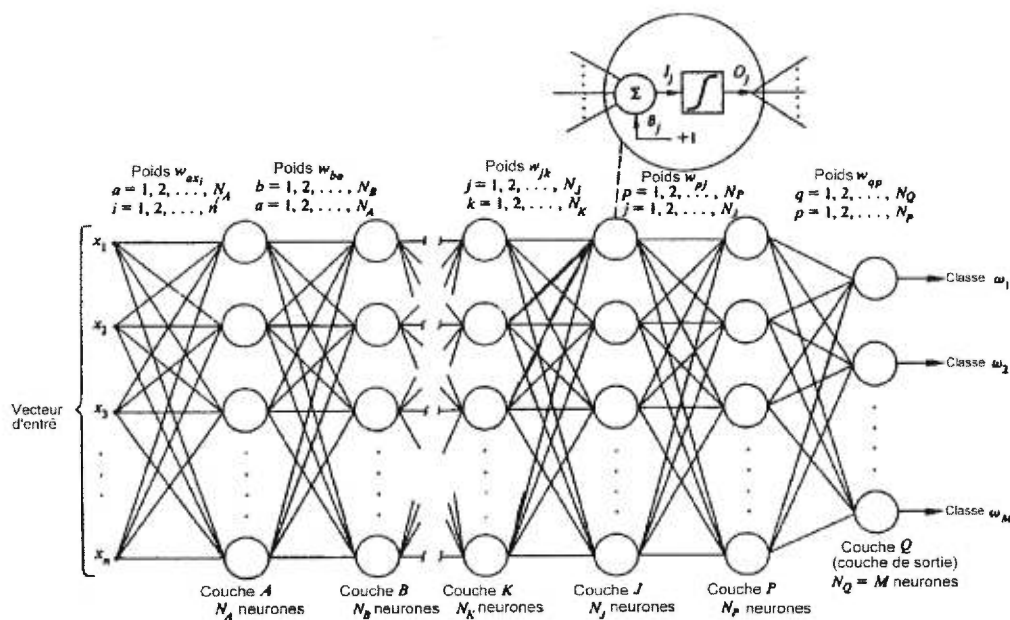


FIG. 5.3 – Structure d'un réseau de neurones à multicouches—Tirée de (Gonzalez et Woods 1992)

Le nombre des neurones dans la couche de sortie Q , est égal à $N_Q = M$, quand M est le nombre de classes d'attributs que le réseau a été entraîné à reconnaître. Le réseau de neurones reconnaît l'appartenance du vecteur d'attributs X à la classe C_m , si la valeur de la sortie à la position m est plus grande que celle des autres sorties du réseau.

Notons que chaque neurone a la même structure que le modèle du perceptron (voir figure 5.2), à l'exception que la fonction d'activation du perceptron est remplacée par une fonction sigmoïde. Sa formule, pour chaque neurone de la couche J , est :

$$h_j(I_j) = \frac{1}{1 + \exp[-(I_j + \theta_j)]} \quad (5.25)$$

où θ_j est un facteur de compensation³. L'entrée d'un neurone se trouvant dans une couche J , représente la somme pondérée de toutes les sorties de la couche précédente K . Ainsi, l'entrée de l'élément d'activation de chaque neurone de la couche J est re-

3. Offset

présentée par I_j calculée comme :

$$I_j = \sum_{k=1}^{N_K} w_{jk} O_k \quad (5.26)$$

pour $j = 1, 2, \dots, N_J$, où N_J est le nombre de neurones dans la couche J et N_K est le nombre de neurones dans la couche K et w_{jk} sont les poids qui modifient les sorties de la couche K tel que: $O_k = h_k(I_k)$ pour $k = 1, 2, \dots, N_K$.

Durant le processus d'apprentissage, adapter les neurones de la dernière couche est chose facile, car la sortie désirée de chaque neurone de cette couche est connue. Le problème principal est l'ajustement des poids dans les couches intermédiaires (couches cachées). C'est pour cela que l'algorithme d'apprentissage par *rétropropagation de l'erreur* a été développé. Cette méthode a pour but de développer une loi d'apprentissage qui ajustera les poids adéquats à chaque neurone de façon à minimiser le coût empirique total E_Q à la sortie. Le coût empirique total est calculé comme :

$$E_Q = \frac{1}{2} \sum_{q=1}^{N_Q} (r_q - O_q)^2 \quad (5.27)$$

où r_q est la réponse désirée et O_q est la réponse réelle obtenue des neurones de la couche de sortie Q .

Le processus d'apprentissage d'un réseau de neurones à multicouches par rétropropagation de l'erreur commence par le choix d'un ensemble arbitraire (mais non identique) de poids partout dans le réseau. Notons que la différentiabilité le long de toutes les trajectoires du réseau de neurones est exigée dans le cadre du développement des lois d'apprentissage par rétropropagation. Par la suite on applique la loi delta généralisée⁴ à chaque étape itérative ce qui impliquera deux phases :

Phase (1) : En premier lieu, le vecteur d'apprentissage est appliqué à l'entrée du réseau et est propagé à travers toutes ses couches afin de calculer la sortie O_j pour chaque

4. *Generalized delta rule. Pour les détails de calcul de cette loi, voir (GONZALEZ et WOODS 1992).*

neurone. Les sorties O_q de tous les neurones de la dernière couche sont alors comparées aux réponses désirées r_q , et les erreurs δ_q sont déterminées.

Phase (2) : En deuxième lieu, on effectue un passage arrière dans le réseau, durant lequel un signal d'erreur approprié traversera chaque neurone, et des changements seront effectués sur les poids correspondants.

Nous répéterons ces procédures plusieurs fois. On dira qu'une session d'apprentissage est réussie, si l'erreur du réseau diminue avec le nombre d'itérations et si la procédure converge vers un ensemble de poids stable. Pour savoir si un vecteur d'attributs a été bien classé durant l'étape d'apprentissage, il suffit de déterminer si la valeur numérique de la sortie du neurone (dans la dernière couche) associée à la classe à laquelle nous supposons que cet attribut appartient est la plus grande, comparée aux réponses des autres neurones de cette couche. Après que le système a été entraîné, le réseau sera capable de classer tous les attributs du vecteur d'entrée en utilisant les paramètres du réseau déterminés durant la phase d'apprentissage.

La méthode des réseaux de neurones à multicouches qui utilisent l'algorithme de rétropropagation de l'erreur fonctionne bien, cela fut montré en pratique. Et ce, même pour des ensembles non linéairement séparables.

5.3 Les méthodes de classification structurelles

Dans le cadre de reconnaissance des formes et classification, si l'image à analyser est composée d'arrangements de primitives, l'utilisation des vecteurs d'attributs s'avère être une technique peu prometteuse. Dans ce cas, les caractéristiques de l'image (ou texture) sont mieux représentées par des relations structurelles, d'où le nom *de méthode structurelle*. Pour mieux illustrer cette approche, référons-nous à l'exemple cité par GONZALEZ et WOODS (1992). Ils considèrent le cas de la reconnaissance des empreintes digitales, basée sur les relations entre des attributs nommés *minutiæ*. Ces attributs représentent des primitives décrivant les propriétés des arêtes

des empreintes telles que: les finitions abruptes, les branchements, les segments déconnectés, etc. Dans le cadre d'un problème de reconnaissance comme celui-ci où il est important de connaître non seulement les mesures quantitatives des attributs mais aussi les relations spatiales existant entre eux afin de déterminer à quelle classe appartient chaque empreinte, il est plus souhaitable d'utiliser les approches structurales. Il existe deux formes de représentations structurales: en forme de chaîne de caractères et en forme d'arbre. Dans le cadre de l'analyse des textures, c'est la représentation linéaire qui s'avère être la plus adéquate.

Considérons l'exemple suivant cité par GONZALEZ et WOODS (1992) : Soit une texture composée de primitives en forme de cercles arrangées de façon à former une matrice 3×3 (figure 5.4).




FIG. 5.4 – Texture composée de primitives en formes de cercles arrangées de façon à former une matrice 3×3

Nous remarquons que notre texture est la répétition de la même primitive. Alors, l'approche la plus simple serait de formuler des relations récursives à l'aide des lois additionnelles suivantes :

- 1) $S \rightarrow aS$
- 2) $S \rightarrow bA$
- 3) $A \rightarrow cA$
- 4) $A \rightarrow c$
- 5) $A \rightarrow bS$

6) $S \rightarrow a$

où a représente un cercle vers la droite, b représente un cercle vers le bas, c représente un cercle vers la gauche, A et S représentent deux variables où S représente le symbole de départ. En appliquant ces lois de la façon suivante :

Les lois	w
(1)	aS
(1)	aaS
(1)	aaaS
(2)	aaabA
(3)	aaabcA
(3)	aaabccA
(5)	aaabccbS
(1)	aaabccbaS
(6)	aaabccbaa

Nous générerons pour cette texture une chaîne de la forme : $w = aaabccbaa$ où la structure de notre texture est parfaitement représentée. Ces lois de placements, en plus de donner une représentation structurale de la texture, peuvent être utilisées afin de créer des textures plus complexes. Cependant cette méthode comprend un grand désavantage, puisque chaque loi n'est pas spécifique à une seule texture. En effet, en utilisant la même loi nous pouvons générer deux textures complètement différentes ce qui n'est pas avantageux pour la modélisation des textures.

Supposons maintenant que nous avons deux textures A et B , codées en forme de chaînes : $w_A = a_1, a_2, \dots, a_n$ et $w_B = b_1, b_2, \dots, b_m$. M représente le nombre de fois qu'une correspondance a été trouvée entre A et B . Une correspondance apparaît à la position k lorsque $a_k = b_k$. Le nombre de symboles qui ne correspondent pas est calculé comme :

$$Q = \max(|A|, |B|) - M \quad (5.28)$$

où $|A|$ et $|B|$ sont les longueurs (nombres de symboles) dans les lignes w_A et w_B respectivement. Il est clair que $Q = 0$ si et seulement si A et B sont identiques. Une mesure simple de la similarité entre A et B est donnée par :

$$R = \frac{M}{Q}. \quad (5.29)$$

La plus grande valeur de R indique le meilleur ajustement. Si $R = \infty$ alors $Q = 0$ et donc, on peut conclure que A et B sont identiques.

Maintenant que nous avons présenté en détail la plupart des méthodes d'analyse de texture, nous nous proposons de décrire dans le chapitre suivant nos applications à l'imagerie SPECT du cerveau.

Chapitre 6

Méthodes et résultats

Ce chapitre est consacré à la présentation des méthodes que nous avons utilisées afin d'analyser des images médicales SPECT de cerveaux et à la description des attributs utilisés afin de classifier ces images. Nous présenterons en détail les cinq approches utilisées dans le cadre de ce mémoire et donnerons les résultats de classification obtenus pour chaque approche.

6.1 Données et problématique

Les images en question sont des images tridimensionnelles de cerveaux de dimensions $64 \times 64 \times 64$. Ce qui signifie que pour chaque cerveau, nous disposons de 64 tranches où chaque tranche représente une image 2D de dimensions 64×64 . Ce découpage est la façon de représenter une image 3D sur l'écran d'ordinateur en médecine nucléaire (voir le chapitre 2). En ce qui nous concerne, nous travaillerons en terme de voxels et donc en 3D. Notons que le terme «image» utilisé dans ce chapitre désigne

une image 3D. Nous disposons de deux classes d'images SPECT de cerveaux que nous nommerons ainsi: *cerveaux à maladie diffuse (CD)* et *cerveaux à maladie focale (CF)*.

- Dans la classe CF, nous disposons de 13 images de cerveaux dit «focaux», ce qui signifie que ces images appartiennent à des patients atteints de maladies focales. Typiquement, on observe un «trou» situé dans une section quelconque du cerveau, cette maladie peut être une tumeur par exemple, une ablation ou une hémorragie (figure 6.1)¹. Cette classe d'images a été filtrée de la même façon que les images de la classe CD.²



FIG. 6.1 – Image 2D d'un cerveau à maladie focale

- Dans la classe CD, nous disposons de 15 images de cerveaux dit «diffus». Ces images appartiennent à des patients atteints de maladies diffuses. Ce genre de maladie peut être n'importe quoi sauf un «trou» (tache sombre apparaissant nettement dans le cerveau, et facilement repérable à l'œil nu). En ce qui concerne les CD, il est plus difficile de les distinguer des cerveaux normaux à l'œil nu; pourtant, une légère variation des niveaux de gris dans l'une des parties de l'image du cerveau peut indiquer une anomalie (figure 6.2).

Le but recherché dans le cadre de ce mémoire, est de trouver le moyen de différencier entre une image représentant un cerveau atteint d'une maladie diffuse et celle

1. Cette image montre un cas extrême de maladie focale. Cependant, il faut souligner que les «trous» ne sont pas aussi évidents dans le reste des cerveaux des images de la classe CF, cette image est représentée à titre explicatif.

2. Nous le savons avec certitude, car le filtrage utilisé dans le processus de reconstruction tomographique des CF et CD a été réalisé par nous-même.



FIG. 6.2 – *Image 2D de cerveau à maladie diffuse*

représentant un cerveau atteint d'une maladie focale à partir d'une analyse de texture 3D.

6.2 Étapes préliminaires

Cette section est consacrée à la description des étapes préliminaires qui ont précédé l'étape de la classification.

6.2.1 Choix du modèle

Nous savons maintenant, en nous basant sur les définitions de la texture citées dans les chapitres précédents, que cette dernière est l'une des plus importantes caractéristiques de l'image. Elle est analysée afin d'identifier des objets ou des régions qui nous intéressent dans une image.

Les images médicales SPECT de cerveaux sont essentiellement produites afin que le médecin puisse en les voyant déterminer si le patient est malade ou pas et afin qu'il puisse déterminer la nature de la maladie s'il y a lieu.

Nous nous sommes donc intéressés à l'analyse des textures afin de pouvoir développer des techniques capables d'aider le médecin durant son diagnostic. Ce qui signifie: prendre une image de cerveau déjà acquise à l'aide d'une caméra Anger et déterminer la nature de la maladie (focale ou diffuse) en essayant de classier cette

image de cerveau malade à sa classe appropriée. Les images que nous avons à notre portée sont des images SPECT, donc des images fortement bruitées. De plus, ce sont des images de cerveaux et donc de tissus mous. Nous caractérisons ce genre d'images comme étant du type *aléatoires* (par opposition à *structurelles*).

Par ces constatations, nous pouvons dire que les méthodes d'analyses statistique sont fortement appropriées à notre cas. Les méthodes d'analyse statistique étant nombreuses, nous avons essayé dans le chapitre 4 de définir celles qui sont le plus utilisées. En procédant par élimination théorique (pour plus de détails à ce sujet, voir les paragraphes suivants), nous nous sommes arrêtés à la méthode des matrices de cooccurrences.

En effet, nous savons que *les moments statistiques* ne nous donnent aucune information sur la position des pixels relativement les uns aux autres dans une image. Aussi, la *méthode des matrices de longueurs de plages* est une approche efficace pour des images composées de textures allongées dans une direction ou une autre, ceci n'étant pas le cas de nos images, nous avons éliminé cette approche.

La méthode des différences des niveaux de gris ressemble à la méthode des matrices de cooccurrences. De plus, elle prend moins d'espace mémoire puisqu'elle calcule un vecteur des différences entre deux intensités voisines. Pourtant, elle est moins efficace que la méthode des matrices de cooccurrences car lors du calcul du vecteur il y a perte d'information puisqu'on perd la valeur absolue du niveau de gris, importante dans une image SPECT de cerveau car les valeurs élevées dans celle-ci correspondent à la matière grise, les valeurs plus faibles à la matière blanche et les régions très sombres au liquide céphalo-rachidien ou à l'arrière plan.

Il existe dans la littérature une méthode d'analyse des textures basée sur les matrices de cooccurrences décrite et proposée par HARALICK, SHANMUGAM et DINSTEIN (1973), cette approche nous la qualifions de *standard*. En ce qui nous concerne, nous avons, pour commencer, appliqué cette approche. Mais par la suite nous avons introduit des modifications à cette méthode tout en gardant les attributs proposés par

HARALICK, SHANMUGAM et DINSTEIN (1973). Par la suite, nous avons remplacé ces attributs et en avons proposé d'autres.

Toutes ces approches seront décrites plus tard, pour le moment commençons par décrire ce que nous avons effectué en prétraitement.

6.2.2 Prétraitement

Nous avons choisi de travailler avec les matrices de cooccurrences, décrites en détail dans le chapitre 4. Ces matrices ont une dimension qui dépend de l'étendue de variation des niveaux de gris dans l'image. Dans notre cas, toutes les images avaient à l'origine des niveaux de gris allant de 0 à 255. Dans ce cas, la dimension de chaque matrice de cooccurrences relative à chaque image aurait été de taille 256×256 (incluant le zéro). Notons qu'une telle dimension est excessivement grande, le temps de calcul de telles matrices aussi bien que le temps qui aurait pris à l'extraction des attributs aurait été très long, sans pour autant améliorer quoi que ce soit à la résolution de notre problème. C'est pour cela que nous avons quantifié les niveaux de gris de toutes les images en ramenant la valeur maximale à 20. Plusieurs méthodes de quantification sont proposées dans la littérature (PRATT 1978), pour notre part, nous avons utilisé la formule³ :

$$I(x,y) = \frac{I(x,y) \times 20}{MAX_{ng}}, \quad (6.1)$$

où MAX_{ng} est la valeur du niveau de gris maximum dans une image, et $I(i,j)$ est la valeur du niveau de gris à la position (i,j) de l'image I . La quantification finie, nous obtenons pour chaque image une matrice de cooccurrences de dimension 21×21 (incluant le zéro). La valeur 20 a été choisie empiriquement, de telle façon à ce que le processus de quantification ne «détruisse» pas nos images et de manière à garder l'es-

3. Il est obligatoire de choisir la valeur maximale des niveaux de gris de l'image quantifiée comme étant une valeur entière car elle représente également la dimension en x et en y des matrices de cooccurrences.

sentiel de l'information utile sur la texture. Aussi, dans les matrices de cooccurrences finales, toutes les valeurs aux positions (i,j) où $i \leq 3$ et $j \leq 3$ ont été ramenées à zéro. Nous n'avons pas cru utile de prendre en considération les cooccurrences des niveaux de gris inférieurs à trois. Ces niveaux de gris correspondent (dans les images) à l'arrière plan bruité ainsi qu'au liquide céphalo-rachidien, ils ne représentent donc pas les tissus cérébraux (qui nous intéressent). Les images (6.2 et 6.3) représentent une image de cerveau originale et son image quantifiée, nous constatons que les deux images se ressemblent.



FIG. 6.3 – Image 2D quantifiée à partir d'une image de cerveau à maladie diffuse (fig. 6.2)

6.2.3 Validation

Pour la classification, nous utilisons une méthode de classification statistique. Plus précisément, le classifieur de Bayes avec un modèle Gaussien (pour plus de détails voir le chapitre 5).

Si nous disposons de deux classes, chacune comprenant un grand nombre de prototypes ou exemples (dans notre cas, chaque prototype est représenté par un vecteur d'attributs), nous aurions partagé les prototypes de chaque classe en deux sous-classes: (1) en prototypes pour le calcul des paramètres du classifieur (ensemble d'entraînement) et (2) en prototypes pour la classification (ensemble test). Pour notre part, afin de déterminer les paramètres du classifieur de Bayes (le vecteur de la moyenne et la matrice de covariance), nous utilisons la validation croisée. Pour en savoir plus sur

cette méthode le lecteur peut consulter par exemple (BENGIO 1998) et (BISHOP 1995). Cette technique permet de remédier au problème de manque de données. Elle consiste à calculer en premier lieu le vecteur de la moyenne et la matrice de covariance en utilisant tous les prototypes de la première classe sauf un, et déterminer ainsi la fonction discriminante pour cette classe. En deuxième lieu, on calcule le vecteur de la moyenne et la matrice de covariance de la deuxième classe en utilisant tous les prototypes de la deuxième classe. On détermine ainsi la fonction discriminante de la deuxième classe. En troisième lieu, on applique aux deux fonctions discriminantes le prototype de la première classe qui n'a pas servi au calcul des paramètres du classifieur. Pour finir on compare les valeurs numériques des deux fonctions discriminantes, si celle de la première classe est supérieure à celle de la deuxième classe cela voudra dire que le prototype a été classé correctement. On procède de la même façon pour tous les prototypes de chaque classe. Notons que dans toutes les méthodes qui vont suivre, le processus de classification est le même que celui décrit ci-dessus.

6.3 Les méthodes

Voyons maintenant les différentes méthodes que nous avons appliquées afin d'extraire de chaque image les attributs nécessaires à l'analyse des textures. Nous proposons deux catégories d'attributs, et pour chacune d'elle trois façons de calculer les matrices de cooccurrences:

- 1) Les attributs d'Haralick : ceux proposés dans (HARALICK, SHANMUGAM et DINSTEIN 1973) et décrits dans le chapitre 4 à la section 4.1.2 seront appliqués au:
 - a) Calcul des matrices de cooccurrences standards, tel que proposé par HARALICK, SHANMUGAM et DINSTEIN (1973) mais avec une légère modification de notre part, plus adaptée au cas de nos images. Cette méthode sera décrite en détail à la section 6.3.1.

- b) Calcul des matrices de cooccurrences par symétrie en utilisant le critère du changement de signe stochastique (SSC) pour trouver le plan mi-sagittal dans chaque cerveau. Ceci est une nouvelle méthode qui sera explorée à la section 6.3.2.
 - c) Calcul des matrices de cooccurrences par symétrie en utilisant le logiciel SPM (Wellcome Department of Cognitive Neurology 1999) pour aligner chaque image de cerveau avec son image miroir. Ceci est aussi une nouvelle méthode qui sera vue en détail à la section 6.3.3.
- 2) Des attributs définis par l'analyse en composantes principales, où nous proposons d'utiliser les premiers paramètres des composantes principales des matrices de cooccurrences comme attributs de la texture. Étant donné que les deux approches: l'une basée sur le calcul du plan mi-sagittal à l'aide du critère du changement de signe stochastique et l'autre basée sur l'alignement de chaque image de cerveau avec son image miroir à l'aide du logiciel SPM se ressemblent — dans les deux cas nous calculons les matrices de cooccurrences par symétrie — nous n'appliquerons l'analyse par composantes principales qu'au:
- a) Calcul des matrices de cooccurrences standards, tel que proposé par Haralick mais avec une légère modification de notre part, plus adaptée au cas de nos images. Cette méthode sera décrite en détail à la section 6.3.4.
 - b) Calcul des matrices de cooccurrences par symétrie en utilisant le logiciel SPM pour aligner chaque image de cerveau avec son image miroir. Cette méthode sera vue en détail à la section 6.3.5. Ces deux méthodes par analyse en composantes principales sont aussi de nouvelles méthodes, élaborées dans le cadre de cette maîtrise.

Nous voyons que nous disposons en tout de cinq façons différentes d'extraire les paramètres des textures. Dans ce qui va suivre nous donnerons en détail les résultats de chaque approche. La notation «Méthode (1a)» voudra dire: l'utilisation des matrices de cooccurrences tel que proposées par Haralick et classification à l'aide des

attributs proposés par Haralick. De même, «Méthode (2b)» voudra dire : calcul des matrices de cooccurrences par symétrie à l'aide du logiciel SPM avec l'utilisation des paramètres des composantes principales comme attributs de la texture.

6.3.1 Méthode (1a)

Dans cette approche, nous calculons pour chaque image 3D de cerveau une seule matrice de cooccurrences de dimension 21×21 . Ce qui diffère quelque peu de la méthode proposée initialement par HARALICK, SHANMUGAM et DINSTEIN (1973), qui proposèrent de calculer pour chaque image quatre matrices de cooccurrences relatives à un angle d'orientation (pour plus de détails voir la section 4.1.2). Pour notre part, nous avons choisi d'intégrer toutes les orientations dans le calcul des matrices de cooccurrences puisque les cerveaux SPECT ne présentent pas de texture orientée. Pour cela, nous considérons non seulement chaque pixel de chaque tranche de cerveau, mais aussi ses six voisins les plus proches (voir schéma 6.4). Un exemple de matrice de cooccurrence est présenté dans la figure 6.5.

À la position $(i,j) = (10,10)$ de la matrice, la valeur $P(i,j) = P(10,10) = 2102$ signifie que, dans cette image de cerveau, le niveau de gris de valeur 10 occure avec un autre niveau de gris de valeur 10 se trouvant ou à sa gauche, à sa droite, au-dessus de lui, au-dessous de lui dans la même tranche; ou en face de lui dans la tranche suivante, ou derrière lui dans la tranche précédente, et ce, à une distance $d = 2$, 2102 fois. Ou en d'autres termes, $P(10,10) = 2102$ indique le nombre de fois où des couples de points séparés par la distance $d = 2$ dans les six directions ont présenté les niveaux de gris 10 et 10.

Les attributs d'Haralick

Après que les matrices de cooccurrences aient été calculées, nous procédons à leur normalisation afin d'obtenir les fréquences relatives nécessaires au calcul des attri-

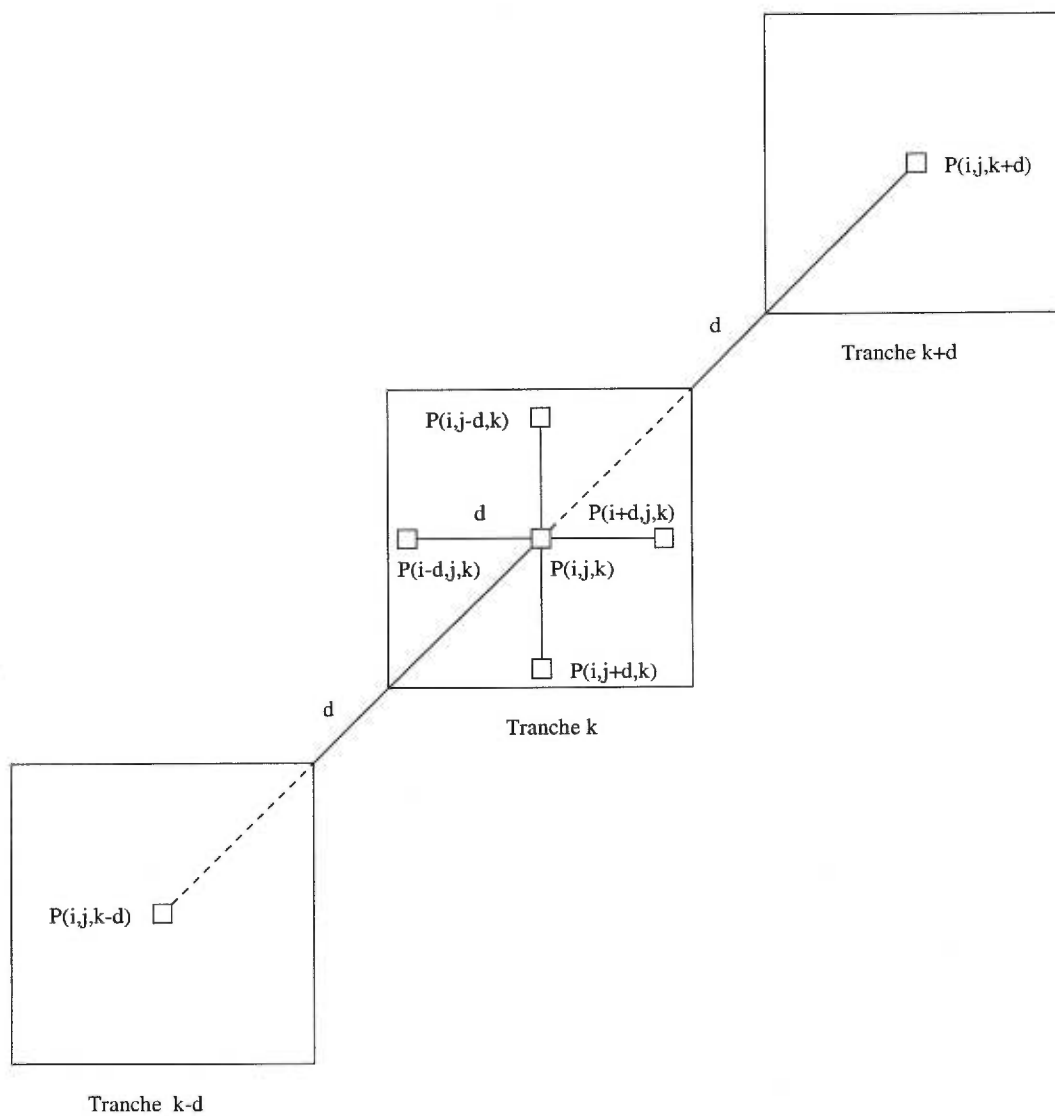


FIG. 6.4 – Illustration graphique des six voisins d'un pixel quelconque d'une image 3D utilisés pour le calcul d'une matrice de cooccurrences de distance interpixel égale à d

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
0	0	0	0	0	1743	4141	3008	2050	1537	955	464	171	81	23	3	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	1743	0	0	0	182	387	317	275	291	192	170	90	35	16	4	0	0	0	0	0	0
5	4141	0	0	0	387	1242	1131	859	819	694	598	442	193	58	23	9	0	0	0	0	0
6	3008	0	0	0	317	1131	1220	940	877	878	752	559	391	144	61	29	1	0	0	0	0
7	2050	0	0	0	275	859	940	1106	988	999	837	717	557	282	89	34	5	0	0	0	0
8	1537	0	0	0	291	819	877	988	1174	1156	1150	937	780	499	204	61	33	0	0	0	0
9	955	0	0	0	192	694	878	999	1156	1696	1771	1363	1119	736	352	137	27	26	1	0	0
10	464	0	0	0	170	598	752	837	1150	1771	2102	1998	1545	1164	544	250	75	28	4	0	0
11	171	0	0	0	90	442	559	717	937	1363	1998	2472	2280	1801	849	441	127	17	8	2	0
12	81	0	0	0	35	193	391	557	780	1119	1545	2280	2990	2721	1381	775	269	47	9	1	0
13	23	0	0	0	16	58	144	282	499	736	1164	1801	2721	3484	1937	1143	504	117	19	4	0
14	3	0	0	0	4	23	61	89	204	352	544	849	1381	1937	1876	1618	793	223	56	6	1
15	0	0	0	0	0	9	29	34	61	137	250	441	775	1143	1618	2072	1271	406	107	17	0
16	0	0	0	0	0	0	1	5	33	27	75	127	269	504	793	1271	1024	521	165	40	5
17	0	0	0	0	0	0	0	0	0	26	28	17	47	117	223	406	521	454	187	55	13
18	0	0	0	0	0	0	0	0	0	1	4	8	9	19	56	107	165	187	158	57	21
19	0	0	0	0	0	0	0	0	0	0	0	2	1	4	6	17	40	55	57	44	26
20	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	5	13	21	26	6

FIG. 6.5 – Illustration d’une matrice de cooccurrences calculée à partir d’un cerveau à maladie diffuse en utilisant la méthode (1a)

but. Les attributs calculés sont au nombre de 4, nous choisissons de travailler qu’avec ceux qui sont les plus couramment utilisés en pratique. Et ils sont: le second moment angulaire (SMA), le contraste (CONT), la corrélation (CORR), l’entropie (ENTR). Pour en savoir plus sur ces attributs, voir la section 4.1.2. Nous utiliserons toutes les combinaisons possibles de trois attributs en même temps, choisis parmi l’ensemble cité plus haut. Et testerons aussi les quatre attributs en même temps. La distance d entre deux pixels voisins a été choisie égale à $d = 2$, car nous supposons — en nous basant sur nos images — que si nous choisissons la valeur de d inférieure à deux, les résultats de la classification seraient les mêmes (ou presque). Par contre, une grande valeur de d dans le cas d’image de cerveaux ne peut être que nuisible. Si la texture de nos images était composée de grandes plages uniformes, il aurait été plus souhaitable d’augmenter la valeur de d afin d’accélérer le temps des calculs, mais cela n’est pas notre cas.

Les résultats

Après que les attributs aient été calculés, nous procédons à la classification en utilisant le classifieur de Bayes et la validation croisée tels que décrits à la section 6.2.3. Les résultats de classifications que nous obtenons ainsi que les erreurs minimales de validation (EV) (pour le choix de variables qui minimisent l'erreur estimée par la validation croisée) commises pour chaque cas se résument dans le tableau 6.1. Pour en savoir plus sur nos résultats voir la section 6.4.

Les attributs	Nbr de CD classés sur 15	Nbr de CF classés sur 13	EV en %
SMA, CONT, CORR	3	10	53.57
SMA, CONT, ENTR	4	11	46.42
SMA, CORR, ENTR	4	10	50
CONT, CORR, ENTR	4	10	50
CONT, ENTR, SMA, CORR	6	9	46.42

TAB. 6.1 – Résultats de la classification des CD et des CF en utilisant les attributs et les matrices de cooccurrences proposés par Haralick

6.3.2 Méthode (1b)

Dans cette approche, nous calculons des matrices de cooccurrences de dimension 21×21 . Toutes les étapes qui suivent celles de calcul des matrices de cooccurrences sont les mêmes que celles évoquées dans la méthode (1a). La différence réside dans la façon dont les matrices de cooccurrences sont calculées. Dans ce cas, nous utilisons le critère du SSC, *critère de changement de signe stochastique* proposé dans (VENOT, LEBRUCHEC et ROUCAYROL 1984) et appliqué dans (MINOSHIMA, BERGER, LEE et MINTUN 1992) pour trouver le plan mi-sagittal des cerveaux. Nous supposons que chaque cerveau est d'une certaine façon symétrique, que son hémisphère gauche est identique à son hémisphère droit (pour un cerveau sain). Nous supposons aussi, que s'il y a malformation (focale ou diffuse) dans l'une des parties du cerveau, il y a de

très faibles chances à ce qu'une malformation semblable à celle-ci soit aussi présente de l'autre côté du plan mi-sagittal du cerveau (par symétrie).

Donc, nous calculons des matrices de cooccurrences où chaque élément $P(i,j)$ déterminera le nombre de fois que le niveau de gris i du côté droit (par rapport au plan mi-sagittal) occure avec le niveau de gris j du côté gauche (par symétrie et par rapport au plan mi-sagittal) du cerveau.

Nous supposons que pour un cerveau sain, par exemple, dans le côté droit du cerveau les niveaux de gris seront, par symétrie, les mêmes que ceux du côté gauche (par rapport au plan mi-sagittal), et donc les valeurs des $p(i,j)$ de la matrice de cooccurrences normalisées seront très grandes surtout sur la diagonale principale. Par contre, s'il y a une malformation du côté droit par exemple, cette partie du cerveau n'aura pas les mêmes niveaux de gris que ceux du côté gauche (par rapport au plan mi-sagittal). Les figures 6.6 et 6.7, illustrent deux matrices de cooccurrences relatives à chaque cas.




FIG. 6.6 – Illustration d'une matrice de cooccurrences calculée à partir d'un cerveau à maladie diffuse en utilisant la symétrie




FIG. 6.7 – Illustration d'une matrice de cooccurrences calculée à partir d'un cerveau à maladie focale en utilisant la symétrie

Maintenant voyons comment contribue le critère du SSC au calcul du plan mi-sagittal.

Le critère du changement de signes stochastique (SSC)

Cette méthode a été décrite dans (MINOSHIMA, BERGER, LEE et MINTUN 1992), tout ce qui va suivre a été tiré de cet article. Cette approche assume une parfaite symétrie des hémisphères droit et gauche du cerveau. Le plan mi-sagittal est déterminé itérativement en optimisant la similarité entre les distributions des activités de l'hémisphère gauche et celles de l'hémisphère droit du cerveau. Cette similarité est calculée à l'aide d'une image SPECT originale et son image miroir, celle-ci est créée en «retournant» l'image SPECT originale par rapport à un plan mi-sagittal présumé. Soit X , Y et Z les axes gauche-droit, antérieur-postérieur et haut-bas, respectivement. La recherche du plan mi-sagittal commence par la rotation de l'image SPECT originale autour du centre de la matrice de l'image dans les plans coronal (XZ) et transversal (XY) par des angles α et β respectivement suivi d'une translation Δx sur l'axe des X . Ainsi, sera créée l'image «tournée» $I_{rot}(x,y,z)$. Cette dernière est alors retournée par rapport à un plan central à la position $X = 0$ que nous supposons pour le moment être le plan mi-sagittal. Ainsi, l'image miroir $I_{mir}(x,y,z)$ sera créée. Ensuite, l'index de similarité SSC_{xyz} est calculé pour les deux images $I_{rot}(x,y,z)$ et $I_{mir}(x,y,z)$ en utilisant le critère du changement de signes stochastique (SSC), qui se fait comme suit:

On calcule d'abord la différence $I_{rot}(x,y,z) - I_{mir}(x,y,z)$. Dans l'ensemble résultant, on calcule la somme de tous les changements de signes le long de l'axe X (sur les tranches transversales), de façon à déterminer l'index de similarité SSC_x . SSC_y est calculé le long de l'axe Y (sur les tranches sagittales), tandis que SSC_z est calculé le long de l'axe Z (sur les tranches coronales). SSC_{xyz} est la somme des SSC_x , SSC_y et SSC_z . Notons que SSC_{xyz} représente la similarité de l'image dans les trois directions. Ce dernier est exprimé en fonction de α , β et Δx . En variant les valeurs des angles α et β ainsi que la valeur de Δx nous répèterons les étapes précédentes et calculerons

à chaque fois la valeur de SSC_{xyz} jusqu'à ce que sa valeur maximale soit atteinte. Dans ce cas les distributions des activités de l'hémisphère droit seront les plus proches possibles de celles de l'hémisphère gauche. Les valeurs α , β et Δx à la valeur maximale de SSC_{xyz} indiquent la position du plan mi-sagittal dans l'image SPECT.

La figure 6.8 illustre une transformation linéaire maximisant le critère du changement de signes stochastique (SSC) pour une image d'ellipse et son image miroir. La figure (A1) montre l'image originale d'une ellipse texturée (tournée de 40 degrés par rapport au plan mi-sagittal), (A2) est son image miroir (par rapport au plan mi-sagittal), tandis que (A3) illustre la différence entre l'image (A1) et (A2). Dans cette image nous remarquons une petite zone, (Z1), correspondant à l'emplacement où il y a un maximum de changements de signes, une autre, (Z2), représentant l'emplacement où la différence est surtout négative (peu de changements de signes) et (Z3) représente la zone où la différence est surtout positive (peu de changements de signes). La figure (B1) montre l'image originale d'une ellipse texturée (tournée de 15 degrés par rapport au plan mi-sagittal), (B2) est son image miroir (par rapport au plan mi-sagittal), tandis que (B3) illustre la différence entre l'image (B1) et (B2). Ici nous remarquons que la zone des changements de signes (Z1) s'agrandit (en comparaison avec l'image (A3)) ce qui indique que le plan de l'image se rapproche du plan mi-sagittal. La figure (C1) montre l'image originale d'une ellipse texturée (tournée de 0 degrés par rapport au plan mi-sagittal), (C2) est son image miroir (par rapport au plan mi-sagittal), tandis que (C3) illustre l'image de la différence entre l'image (C1) et (C2). Ici nous remarquons que la zone des changements de signes (Z1) — qui correspond à toute la surface de l'ellipse — est plus grande que celle des images (A3) et (B3) et les zones (Z2) et (Z3) sont inexistantes, ce qui indique que le plan de l'image est le plan mi-sagittal.

Les résultats

Après que les matrices de cooccurrences aient été calculées conformément à cette technique, elles sont normalisées et les mêmes attributs que ceux décrits dans la mé-




FIG. 6.8 – Transformation linéaire maximisant le critère du changement de signes stochastique (SSC) pour une image d'ellipse et son image miroir (voir plus de détails dans le texte)

thode (1a) sont calculés (voir la section 6.3.1). Pour finir nous procédons à la classification de la même façon que dans la méthode (1a) et tel que décrit à la section 6.2.3. Les résultats de classifications que nous obtenons ainsi que les erreurs minimales de validation (EV) (pour le choix de variables qui minimisent l'erreur estimée par la validation croisée) commises pour chaque cas sont décrits dans le tableau 6.2. Pour en savoir plus sur nos résultats voir la section 6.4.

Les attributs	Nbr de CD classés sur 15	Nbr de CF classés sur 13	EV en %
SMA, CONT, CORR	9	8	39.28
SMA, CONT, ENTR	11	6	39.28
SMA, CORR, ENTR	7	12	32.14
CONT, CORR, ENTR	12	7	32.14
SMA, CONT, CORR, ENTR	10	7	39.28

TAB. 6.2 – Résultats de la classification des CD et des CF en utilisant les attributs proposés par Haralick et le critère SSC

6.3.3 Méthode (1c)

Dans cette méthode nous calculons des matrices de cooccurrences de dimension 21×21 pour chaque type de cerveau. Cette approche est réalisée à l'aide du logiciel SPM, qui consiste à calculer d'abord pour chaque image originale I_o de cerveau son image miroir 3D I_m . En utilisant le logiciel SPM (Wellcome Department of Cognitive Neurology 1999) nous procédons à l'alignement (recalage) des deux images, de sorte que I_o soit parfaitement alignée avec son image miroir I_m . Les détails de cette procédure sont décrits dans la section suivante.

Le recalage

Soit deux images à recaler dont l'intensité au point (voxel) (x,y,z) est donnée par les deux fonctions $f(x,y,z)$ et $g(x,y,z)$. Si nous supposons que la différence entre ces deux images peut être attribuée uniquement à une déformation spatiale, on peut alors

écrire:

$$g(x,y,z) = f(H[x,y,z; \gamma]) + e(x,y,z). \quad (6.2)$$

Où H est une transformation définie par un ensemble de paramètres γ , et e représente un terme d'erreur. Le logiciel SPM calcule itérativement la transformation H qui va minimiser le terme d'erreur (par moindres carrés après avoir linéarisé le problème avec un développement en série de Taylor (FRACKOWIAK, FRISTON et MAZZIOTTA 1997)). Sans contraintes ce problème serait très mal posé (car il est question alors de travailler avec trop d'inconnues). Pour le résoudre, le logiciel calcule d'abord la meilleure transformation affine (linéaire) permettant de recalibrer l'intensité $f(x,y,z)$ de la première image sur l'intensité $g(x,y,z)$ de la deuxième image. Par la suite, le logiciel cherche une transformation non-linéaire lisse. Cette contrainte signifie que H change doucement en fonction de la position ce qui est réaliste pour des images médicales du cerveau comme les nôtres. Le lissage est obtenu en recherchant une transformation non-linéaire consistant en une combinaison linéaire de fonctions de base non-linéaires, lisses indépendantes et orthogonales. Ces fonctions, dans SPM, sont les premières harmoniques (basses fréquences) de la transformée cosinus discrète 3D. Trouver la transformation non-linéaire consiste donc à trouver les coefficients affectant chacune des fonctions cosinus. Cette technique de recalage se révèle très efficace et est aujourd'hui très utilisée pour le recalage d'images de cerveaux (SPECT, PET⁴ et IRM⁵). Il est aussi à noter que cette méthode dans une version plus complexe permet au besoin de considérer des images d'intensités différentes ou encore issues de modalités d'imagerie différentes (ce qui n'est pas notre cas). Pour en savoir plus sur l'implantation de la méthode, se référer au troisième chapitre du livre de (FRACKOWIAK, FRISTON et MAZZIOTTA 1997).

4. Positron emission tomography

5. Images par résonance magnétique

Les résultats

Par la suite nous calculons pour chaque image de cerveau sa matrice de cooccurrences. Chaque élément de la matrice à la position (i,j) représente le nombre de fois que le niveau de gris i situé à la position (x,y,z) de l'image I_o occure avec le niveau de gris j situé à la même position (x,y,z) mais sur l'image I_m . Le but recherché par cette approche est le même que celui de la méthode (1b), celui de comparer pour chaque cerveau les hémisphères droit et gauche. Les matrices étant calculées et normalisées, nous calculons les attributs de la texture pour chaque matrice de cooccurrences correspondant à un cerveau donné. Les attributs utilisés sont les mêmes que ceux utilisés dans les méthodes (1a) et (1b) (voir la section 6.3.1). Cette étape finie, nous procédons à la classification en utilisant le classifieur de Bayes et la validation croisée de la même façon que pour les méthodes (1a) et (1b) (voir les détails dans la section 6.2.3). Les résultats de classifications que nous obtenons ainsi que les erreurs minimales de validation (EV) (pour le choix de variables qui minimisent l'erreur estimée par la validation croisée) commises pour chaque cas figurent dans le tableau 6.3. Pour en savoir plus sur nos résultats voir la section 6.4.

Les attributs	Nbr de CD classés sur 15	Nbr de CF classés sur 13	EV en %
SMA, CONT, CORR	9	10	32.14
SMA, CONT, ENTR	13	9	21.42
SMA, CORR, ENTR	14	10	14.28
CONT, CORR, ENTR	13	9	21.42
SMA, CONT, CORR, ENTR	12	10	21.42

TAB. 6.3 – Résultats de la classification des CD et des CF en utilisant les attributs proposés par Haralick et les matrices de cooccurrences calculées à l'aide du logiciel SPM

6.3.4 Méthode (2a)

Dans cette approche nous calculons pour chaque cerveau une matrice de cooccurrences de la même façon que nous l'avons fait pour la méthode (1a) (voir la section 6.3.1). Toutes les matrices ont été par la suite normalisées.

Cependant, les attributs de texture que nous utilisons durant la phase de classification sont différents de ceux calculés dans les méthodes (1a), (1b) et (1c). Nous utilisons l'analyse par composantes principales (ACP) afin de calculer les paramètres α , β , γ et δ qui joueront le rôle des attributs de texture. Ceci se fait comme suit.

Analyse par composantes principales

Pour essayer de bien définir cette approche, nous l'illustrons à partir d'un exemple concret. Nous n'utiliserons que le cas des CF. Il reste à souligner que tout ce qui sera dit au sujet des CF va être également fait pour toutes les autres images de la classe CD. Nous commençons par utiliser la transformation de Hotelling (GONZALEZ et WOODS 1992), cette méthode est basée sur les propriétés statistiques des vecteurs d'attributs. Soit les 13 matrices de cooccurrences chacune représentant un cerveau de l'ensemble des cerveaux à maladie focale (CF). À partir de toutes ces matrices nous calculons des vecteurs X comme le montre la figure 6.9.

Soit un vecteur $X_{(i,j)} = (X_1^{i,j}, X_2^{i,j}, \dots, X_{13}^{i,j})^T$ composé des fréquences relatives, et de dimension $n = 13$, où n est le nombre des matrices de cooccurrences misent en jeu. $X_1^{i,j}$ correspond à la valeur de la fréquence relative à la position (i,j) de la matrice de cooccurrence MC_1 , ..., et $X_{13}^{i,j}$ correspond à la valeur de la fréquence relative à la position (i,j) de la matrice MC_{13} . Nous savons que la dimension de toutes les matrices de cooccurrences est de 21×21 , ce qui nous donne $21 \times 21 = 441$ vecteurs, à l'aide

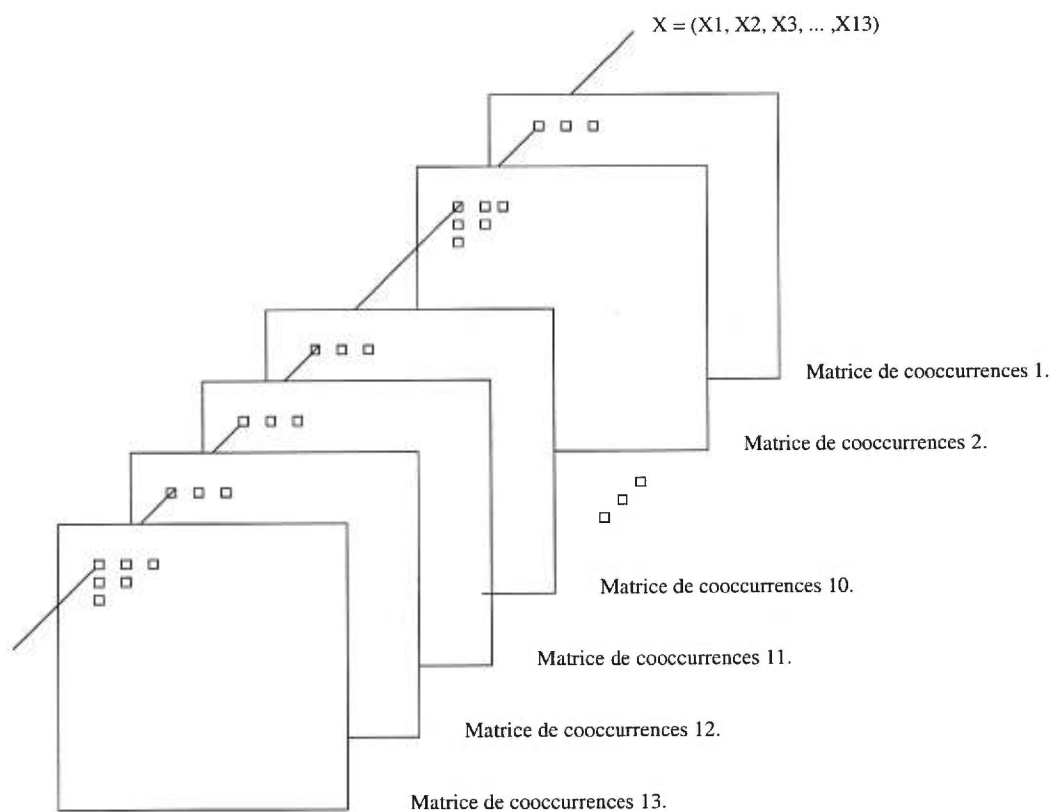


FIG. 6.9 – Formation d'un vecteur d'attributs à partir des valeurs appartenant à 13 matrices de cooccurrences

desquels nous calculons le vecteur de la moyenne:

$$m_X = \frac{1}{21 \times 21} \sum_{i=1}^{21} \sum_{j=1}^{21} X_{(i,j)} \quad (6.3)$$

et la matrice de covariance:

$$C_X = \frac{1}{21 \times 21} \sum_{i=1}^{21} \sum_{j=1}^{21} X_{(i,j)} \cdot X_{(i,j)}^T - m_X m_X^T \quad (6.4)$$

Parce que C_X est par définition une matrice réelle et symétrique, nous pouvons calculer un ensemble de $n = 21$ vecteurs propres orthogonaux. Soit e_i et λ_i , $i = 1, 2, \dots, n$, les vecteurs propres et leurs valeurs propres respectives, tous calculés à partir de la matrice de covariance C_X . Soit A une matrice composée à partir des vecteurs propres de C_X , ordonnée de telle façon à ce que la première ligne comprend le vecteur propre correspondant à la plus grande valeur propre, et la dernière ligne comprend le vecteur propre correspondant à la plus petite valeur propre de C_X . A est une matrice qui transforme un vecteur X en un autre vecteur Y tel que:

$$Y_{(i,j)} = A(X_{(i,j)} - m_X). \quad (6.5)$$

L'équation (6.5) est appelée *la transformation de Hotelling*. Son but est de décorréler les vecteurs X en les transformant en vecteurs Y . En effet, on peut montrer que C_Y (la matrice de covariance des vecteurs Y) est une matrice diagonale dont les éléments sont les valeurs propres de C_X (GONZALEZ et WOODS 1992). Le tableau 6.4 et le graphique 6.10 montrent les valeurs propres de C_X . Notons que plus les valeurs de ce tableau sont élevées, plus les composantes principales qui leurs sont associées ont un contenu important en information (variance élevée).

Nous remarquons à partir du graphique 6.10 que les valeurs propres tombent très vite, et à partir d'un certain seuil elles se stabilisent. Si on ne retient que les quatre

λ_1	4216520
λ_2	166018
λ_3	37818.3
λ_4	24709.6
λ_5	12344
λ_6	9391.93
λ_7	5035.31
λ_8	3116.46
λ_9	1772.51
λ_{10}	1580.56
λ_{11}	1196.46
λ_{12}	883.663
λ_{13}	531.317

TAB. 6.4 – Les valeurs propres de la matrice de covariance calculée à partir des matrices de cooccurrences des CF




FIG. 6.10 – Illustration graphique des valeurs propres de la matrice de covariance calculée à partir des matrices de cooccurrences des CF

premières composantes par exemple⁶, la matrice A ne comprendra que les quatre premiers vecteurs propres associés aux quatre valeurs propres prédominantes. La figure 6.11 illustre un exemple de quatre composantes principales Y_1, Y_2, Y_3 et Y_4 pour le cas des CF.




FIG. 6.11 – Illustration des quatre premières composantes principales calculées à partir des matrices de cooccurrences des cerveaux à maladie focale

En essayant de reconstruire chaque matrice de cooccurrences originale, en appliquant l'inverse de l'équation 6.5 et en ne retenant que quatre composantes principales (les autres étant mises à zéro) nous obtenons:

$$X_k \approx \alpha_k Y_1 + \beta_k Y_2 + \gamma_k Y_3 + \delta_k Y_4 \quad (6.6)$$

pour $k = 1, 2, \dots, 13$, le nombre de matrices de cooccurrences, chacune étant associée à une image de cerveau de l'ensemble CF. $\alpha_k, \beta_k, \gamma_k$ et δ_k sont les coefficients (poids) des composantes principales associés à la k -ème matrice de cooccurrences, et par

6. Nous aurions pu ne retenir que la première composante principale associée à la première valeur propre illustrée sans le tableau 6.4 car cette valeur est très prédominante et notre supposition première était que nous pourrions classifier juste avec ce paramètre, mais nous avons choisi de tester les trois autres (dont les valeurs restent élevées) aussi pour pouvoir vérifier notre supposition.

conséquent ceux sont les attributs de texture de l'image associée à cette matrice. Pour chaque matrice, nous obtenons ainsi quatre attributs.

Les résultats

En variant le nombre des coefficients (attributs), nous procédons à la classification. De la même façon que pour les méthodes précédentes, nous utilisons le classifieur de Bayes et la validation croisée. Nous commençons par appliquer le coefficient α au classifieur de Bayes — étant donné qu'il est le plus important — ensuite nous rajoutons à fur et à mesure les autres.

Les résultats de classifications que nous obtenons ainsi que les erreurs minimales de validation (EV) (pour le choix de variables qui minimisent l'erreur estimée par la validation croisée) commises pour chaque cas sont décrits dans le tableau 6.5. Pour en savoir plus sur nos résultats voir la section 6.4.

Les attributs	Nbr de CD classés sur 15	Nbr de CF classés sur 13	EV en %
α	8	6	50
α, β	9	6	46.42
α, β, γ	9	7	42.85
$\alpha, \beta, \gamma, \delta$	9	8	39.28

TAB. 6.5 – Résultats de la classification des CD et des CF en utilisant les matrices de cooccurrences proposées par Haralick et l'ACP pour le calcul des attributs de la texture

6.3.5 Méthode (2b)

Ici nous calculons des matrices de cooccurrences de dimensions 21×21 pour chaque type de cerveau de la même façon que nous l'avons fait dans la méthode (1c) (voir la section 6.3.3). Après avoir normalisé toutes les matrices, nous en extrayons les attributs de texture, qui représentent les composantes principales, comme il a été fait dans la méthode (2a) (voir la section 6.3.4). Et pour finir, nous effectuons des classifications de la même manière que dans toutes les étapes précédentes. Les résultats de

classifications que nous obtenons ainsi que les erreurs minimales de validation (EV) (pour le choix de variables qui minimisent l'erreur estimée par la validation croisée) commises pour chaque cas sont représentés dans le tableau 6.6. Pour en savoir plus nos résultats voir la section 6.4.

Les attributs	Nbr de CD classés sur 15	Nbr de CF classés sur 13	EV en %
α	15	13	0
α, β	15	13	0
α, β, γ	15	13	0
$\alpha, \beta, \gamma, \delta$	15	13	0

TAB. 6.6 – Résultats de la classification des CD et des CF en utilisant les matrices de cooccurrences calculées à l'aide du logiciel SPM et l'analyse en composantes principales pour le calcul des attributs de texture

6.4 Conclusion

En nous basant sur les résultats obtenus grâce aux méthodes décrites plus haut, nous pouvons maintenant évaluer le risque empirique (RE) minimal obtenu pour chaque cas. Le tableau suivant résume les combinaisons d'attributs qui ont permis lors de la classification d'obtenir le risque empirique minimal pour chaque méthode et le RE correspondant:

Les méthodes	Les attributs	RE en %
Methode (a1)	(SMA, CONT, ENTR), (CONT, SMA, ENTR, CORR)	46.42
Methode (a2)	(SMA, CORR, ENTR), (CONT, CORR, ENTR)	32.14
Methode (a3)	SMA, CORR, ENTR	14.28
Methode (b1)	$\alpha, \beta, \gamma, \delta$	39.28
Methode (b2)	Toutes les combinaisons	0

TAB. 6.7 – Risques empiriques minimaux correspondants à des combinaisons d'attributs appliquées à chaque type de méthode

Cependant, nous voulons connaître les erreurs de généralisation (EG) et non les erreurs d'apprentissage pour pouvoir dire avec exactitude quelles combinaisons d'attributs fonctionnent le mieux et pour quelle méthode. Nous désirons donc estimer le risque espéré (erreur de généralisation), cela nous est permis grâce à une formule pro-

posée par VAPNIK (1998). Mais avant, voyons quelques définitions tirées de (BENGIO 1998) et (VAPNIK 1998):

Considérons un ensemble de données $D_l = (z_1, z_2, \dots, z_l)$, les points sont tirés d'une manière indépendante de la même distribution inconnue $P(Z)$. Soit un ensemble de fonctions \mathcal{F} , il est possible de mesurer la qualité (i.e., le coût) d'une solution sur un $Z = z$ particulier à l'aide de la fonction $Q(z, f)$ en sachant que $f \in \mathcal{F}$.

Supposons que nous désirons minimiser le risque espéré (l'erreur de généralisation) représenté par la formule suivante:

$$R(f) = \int_z Q(z, f) P(z) dz, \quad (6.7)$$

qui mesure l'erreur espérée et ce, en appliquant la fonction f sur un exemple tiré au hasard d'une distribution inconnue $P(Z)$.

Afin de minimiser l'erreur de généralisation faite sur l'ensemble D_l il est de coutume d'utiliser les principes de minimisation de la fonction du risque empirique suivante:

$$R(f, D_l) = \frac{1}{l} \sum_{i=1}^l Q(z_i, f), \quad (6.8)$$

qui est l'erreur faite par une fonction f particulière sur les exemples D_l .

La fonction qui permet de borner l'erreur de généralisation en se basant sur l'erreur empirique est donnée par la fonction suivante proposée par (VAPNIK 1998):

$$R(f) < R_{\text{emp}}(f, D_l) + \frac{\ln(N) - \ln(\eta)}{l} \left(1 + \sqrt{1 + 2 \frac{R_{\text{emp}}(f, D_l) l}{\ln(N) - \ln(\eta)}} \right). \quad (6.9)$$

Où N représente la capacité de \mathcal{F} (le nombre de fonctions), donc le nombre de combinaisons d'attributs appliquées pour chaque cas, l est le nombre d'exemples, plus

précisément le nombre d'images de cerveaux SPECT et le paramètre $\eta = 1 - p$, où p est la probabilité minimale avec laquelle on peut énoncer l'inégalité sur l'erreur de généralisation espérée. Nous choisissons $\eta = 0.1$, ce qui détermine un énoncé vrai pour au moins 90% des cas.

En tenant compte du tableau 6.7 et en appliquant nos données — soit $\eta = 0.1$, $l = 28$, $N = 5$ pour les méthodes 6.3.1, 6.3.2 et 6.3.3; et $N = 4$ pour les méthodes 6.3.4 et 6.3.5 — à l'équation 6.9, nous obtenons les résultats du tableau 6.8 qui résume les combinaisons d'attributs qui ont permis lors de la classification d'obtenir le risque empirique minimal pour chaque méthode et la borne inférieure de l'erreur de généralisation correspondante:

Les méthodes	Les attributs	R(f) < %
Methode (a1)	(SMA, CONT, ENTR), (CONT, SMA, ENTR, CORR)	99.09
Methode (a2)	(SMA, CORR, ENTR), (CONT, CORR, ENTR)	79.24
Methode (a3)	SMA, CORR, ENTR	52.68
Methode (b1)	$\alpha, \beta, \gamma, \delta$	78.99
Methode (b2)	Toutes les combinaisons	20

TAB. 6.8 – Borne inférieure des risques espérés correspondants à des combinaisons d'attributs appliquées à chaque type de méthode

Chapitre 7

Discussion et conclusion

À l'origine, nous disposions de trois classes d'images SPECT de cerveaux que nous avons définies ainsi : (a) *cerveaux à maladie diffuse (CD)*, (b) *cerveaux à maladie focale (CF)* et (c), *cerveaux normaux (CN)*.

1. Dans la classe CD, nous disposions de 15 cerveaux dit «diffus».
2. Dans la classe CF, nous disposions de 13 cerveaux dit «focaux».
3. Dans la classe CN, nous disposions de 19 cerveaux dit «normaux», classe elle-même subdivisée en trois sous-classes: PN1 (pour *patients normaux groupe 1*), PN2 (pour *patients normaux groupe 2*) et VN (pour *volontaires normaux*).
 - (a) Dans la classe PN1, nous disposions de 2 images de cerveaux appartenant à des patients dont le diagnostic s'est avéré être négatif. Nous avons filtré nous-mêmes les images de cette classe, et ce, de la même façon que les classes CD et CF.
 - (b) Dans la classe PN2, nous disposions de 7 images de cerveaux appartenant à des patients dont le diagnostic s'est aussi avéré être négatif. Nous n'avons pas filtré nous-mêmes les images de cette classe.
 - (c) Dans la classe VN, nous disposions de 10 images de cerveaux appartenant à des volontaires sains. La qualité de ces images est nettement meilleure que

celle des classes PN1 et PN2. Les volontaires, n'étant pas sujets au stress du diagnostic, n'avaient pas tendance à bouger lors de la phase d'acquisition. Nous n'avons pas filtré nous-mêmes les images de cette classe de CN.

Notre but premier était de pouvoir aider le médecin lors du dépistage de maladies du cerveau. Nous avons voulu élaborer une méthode capable de différencier entre un cerveau malade et un autre sain. Par la suite, cette méthode aurait permis de distinguer entre deux types de maladies — focale et diffuse. Nous nous sommes aperçus que les deux classes de cerveaux, VN et PN2, n'ont pas été filtrées de la même façon que les PN1. Il était donc impossible de regrouper ces trois classes sous une classe unique, CN. De plus, comme la classe CN1 a été filtrée par nous-mêmes et de la même façon que les classes CF et CD mais pas de la même façon que les PN2 et VN, il était clair que ce serait une erreur de vouloir comparer les CF et les CD versus les PN1 et VN : nous aurions alors distingué entre deux filtrages différents et non entre deux classes différentes de cerveaux (nous avons observé ce phénomène sur nos premiers résultats). C'est ce filtrage différent qui nous a poussé à éliminer les classes PN2 et VN. La classe PN1, de son côté, a été éliminée car elle ne contenait que deux images de cerveaux. Nous avons donc reformulé l'objectif de ce mémoire comme le développement d'une approche capable de différencier efficacement une image de cerveau à maladie diffuse (CD) d'une autre d'un cerveau à maladie focale (CF), de façon à placer chaque type de cerveau dans sa classe appropriée.

Pour commencer, nous avons utilisé l'analyse de texture en utilisant les matrices de cooccurrences (MC), tel que proposé par HARALICK, SHANMUGAM et DINSTEIN (1973), de même que les attributs proposés par ces derniers. Pour chaque cerveau de deux classes, nous avons calculé une matrice de cooccurrences englobant toute l'information spatiale des textures, tel que décrit à la section 6.3.1. En étudiant toutes les combinaisons possibles de 3 attributs en même temps, choisi parmi l'ensemble des 4 attributs principaux (incluant le cas des quatre attribus) et en les appliquant au classifieur de Bayes, le meilleur taux de classification — pour les CD et CF — que nous

ayons pu atteindre a été de 53.58% (l'erreur de généralisation pour cette méthode étant $R(f) < 99.09\%$ avec une confiance $> 90\%$)¹. Ce faible taux de classification est dû au fait que les matrices de cooccurrences calculées à la manière d'Haralick sont peu adaptées au cas d'images de cerveaux. En effet, les taches sombres dans les CF — correspondant aux tumeurs, hémorragies ou ablations — ont les mêmes niveaux de gris (ou presque) que l'arrière-plan et les régions contenant du liquide céphalo-rachidien et se confondent donc avec ces derniers. Comme nous l'avons expliqué à la section 6.2.2, le prétraitement terminé, dans les matrices de cooccurrences finales, toutes les valeurs aux positions (i,j) où $i \leq 3$ et $j \leq 3$ ont été ramenées à zéro. En éliminant les niveaux de gris correspondant à l'arrière-plan et au liquide céphalo-rachidien (afin d'étudier seulement les parties du cerveau), on élimine également les zones des images relatives aux maladies focales, ce qui produit une perte d'information. Dans ce cas, nous ne pouvons plus comparer une image de cerveau ayant une tache sombre avec une autre n'en ayant pas. Pour pouvoir conserver cette information, nous avons choisi de procéder comme le médecin lors de son diagnostic. Celui-ci compare les deux hémisphères — gauche et droit — de chaque cerveau, qui sont sensés être symétriques et identiques, dans le cas d'un cerveau sain. Comme il existe de faibles probabilités que la même anomalie (si anomalie il y a) apparaisse dans les deux hémisphères au même endroit (par symétrie par rapport au plan mi-sagittal), le médecin peut déterminer la présence d'une anomalie par simple comparaison des deux hémisphères. C'est pour cette raison que nous avons décidé de calculer les matrices de cooccurrences par symétrie par rapport au plan mi-sagittal, tel que décrit aux sections 6.3.2 et 6.3.3. Les deux techniques décrites à ces sections se ressemblent fortement: dans le premier cas, on détermine le plan mi-sagittal à l'aide du critère de changement de signes stochastique (SSC), et on calcule les matrices de cooccurrences par symétrie par rapport à ce plan; dans le deuxième cas, nous utilisons le logiciel SPM (Wellcome Department of Cognitive Neurology 1999) afin de recalibrer chaque image de cerveau avec son image miroir et

1. Les pourcentages ont été calculés à partir des taux de classification des deux classes en même temps.

calculons les matrices de cooccurrences pour chaque cas, en comparant chaque image originale avec son image miroir (ce qui revient à calculer des matrices de cooccurrences par symétrie). Nous avons utilisé ces deux approches à titre comparatif, dans le but de déterminer si la méthode SSC donnerait d'aussi bons résultats qu'un logiciel disponible sur le marché. Le meilleur taux de réussite pour la méthode de la section 6.3.2 est de 67.86% (l'erreur de généralisation pour cette méthode étant $R(f) < 79.24\%$ avec une confiance $> 90\%$), ce qui est supérieur au taux obtenu en utilisant la méthode de la section 6.3.1. Pour la méthode de la section 6.3.3 le taux maximum de réussite est de 85.72% (l'erreur de généralisation pour cette méthode étant $R(f) < 52.68\%$ avec une confiance $> 90\%$), un résultat encore supérieur. Nous sommes donc parvenus à classer correctement les CD et les CF en utilisant trois attributs de la texture (SMA, CORR et ENTR).

Toutefois, l'utilisation des 12 attributs proposés par HARALICK, SHANMUGAM et DINSTEIN (1973) comporte des inconvénients : la grande variété des attributs fait qu'il est difficile de déterminer avec exactitude lesquels sont les plus appropriés à notre cas.

À fin de remédier à ces inconvénients, nous avons jugé bon d'utiliser non pas les attributs d'Haralick, mais des paramètres calculés à partir de l'analyse en composantes principales, tels que décrits à la section 6.3.1. Les composantes principales (CP) étant calculées sur l'ensemble des matrices de cooccurrences de chaque classe, nous sommes parvenus ainsi à cerner toute l'information utile sur les textures de toutes les images de chaque classe.

Nous savons, grâce au graphique 6.4, que ce ne sont pas toutes les CP qui portent en elles de l'information utile. Pour cette raison, nous nous sommes limités à un maximum de quatre CP, et ainsi, à quatre paramètres : α , β , γ et δ . Nous nous sommes retrouvés ainsi avec quatre d'attributs qui, de plus, englobent beaucoup plus d'information (sur l'ensemble des matrices de cooccurrences). Pour pouvoir tester l'efficacité de cette méthode, nous l'avons testée sur les matrices de cooccurrences, calculées dans le cas ayant le mieux fonctionné préalablement (6.3.3) et sur celui ayant le moins

bien fonctionné (6.3.1). Les résultats se sont avérés plus qu'encourageants : le taux des images correctement classées pour le cas des matrices de cooccurrences telles que proposées par Haralick est de 60.72% (l'erreur de généralisation pour cette méthode étant $R(f) < 78.99\%$ avec une confiance $> 90\%$), tandis que le taux est de 100% (l'erreur de généralisation pour cette méthode étant $R(f) < 20\%$ avec une confiance $> 90\%$) pour des matrices de cooccurrences calculées par symétrie en utilisant le logiciel SPM. Ceci reste vrai même si l'on n'utilise qu'un seul attribut, celui correspondant à la CP qui elle-même correspond à la plus grande valeur des valeurs propres (voir le tableau 6.4).

Grâce aux résultats assez satisfaisants ainsi obtenus, nous savons désormais qu'il est possible de classifier deux catégories de cerveaux en utilisant les matrices de cooccurrences calculées par symétrie et l'analyse par composantes principales afin de calculer les attributs de la texture et réduire leur nombre. Pourtant, nous prévoyons obtenir des résultats plus satisfaisants et plus représentatifs, par l'utilisation de classes comprenant un nombre plus élevé d'exemples ; ceci nous permettrait, 1^o de départager cet ensemble en deux sous-ensembles — test et entraînement — et, 2^o pour pouvoir tester nos hypothèses sur un nombre plus élevé de données. De plus, si nous pouvions disposer d'une troisième classe d'images de cerveaux (des cerveaux sains), et nous assurer que toutes les images aient été filtrées de la même façon, de façon à diminuer les erreurs, nous pourrions alors appliquer notre méthode afin de classifier des images de cerveaux malades versus des images de cerveaux sains. Voilà des propositions que nous nous suggérons d'explorer lors de nos travaux futurs.

Références

- BENGIO, Y. (1998), « Notes du cours IFT6266 (Automne 98) », Disponible à <http://www.iro.umontreal.ca/bengioy/ift6266/>.
- BESAG, J. (1974), « Spatial Interaction and the Statistical Analysis of Lattice Systems (with discussion) », *Journal of the Royal Statistical Society* 36, pp. 192--326.
- BISHOP, C. M. (1995), *Neural Networks for Pattern Recognition*, Oxford: Oxford University Press.
- BORDATZ, P. (1956,), *Texture: A photographic Album for Artists and Designers*. Dover.
- BURRILL, J. H. P. (1997), « Texture Mapping of Neurological Magnetic Resonance Images », Disponible à <http://www.burrill.demon.co.uk/meddoc/tmmri.html>.
- CHEN, P. C. et T. PAVLIDIS (1979), « Segmentation by Texture Using a Co-Occurrence Matrix and Split-and-Merge Algorithm », *Computer Graphics and Image Processing* 10, pp. 172--182.
- CHEN, Y. Q., M. S. NIXON et D. W. THOMAS (1995), « Statistical Geometrical Features for Texture Classification », *Pattern Recognition* 28(4), pp. 537--552.
- COHEN, P. R. et E. A. FEIGENBAUM (1982), *The Handbook of Artificial Intelligence*.
- CONNERS, R. W. et C. A. HARLOW (1980), « A Theoretical Comparison of Texture Algorithms », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2(3), pp. 204--222.
- CROFT, B. Y. (1986), *Single-Photon Emission Computed Tomography*, Chicago, IL: Yearbook Medical Publishers.
- CROSS, G. R. et A. K. JAIN (1983), « Markov Random Field Texture Models », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 5(1), pp. 25--39.
- DERIN, H. et H. ELLIOTT (1987), « Modeling and Segmentation of Noisy and Textured Images Using Gibbs Random Fields », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 9(1), pp. 39--55.
- DERIN, H., H. ELLIOTT, R. CRISTI et D. GEMAN (1984), « Bayes Smoothing Algorithms for Segmentation of Binary Images Modeled by Markov Random Fields », *IEEE Transactions on*

- Pattern Analysis and Machine Intelligence* 6(6), pp. 707--720.
- DILHUYDY, H. (1991), *Visualisation et quantification tridimensionnelle de la nécrose myocardique en médecine nucléaire*, Mémoire de maîtrise, Université de Montréal, École Polytechnique.
- DUBES, R. C. et A. K. JAIN (1989), « Random Field Models in Image Analysis », *Journal of Applied Statistics* 16(2), pp. 131--164.
- EVANS, S. (1994), *An investigation of the potential use of Technetium-99m-HMPAO SPECT scanning in decompression illness*, Thèse de doctorat, The Robert Gordon University.
- FRACKOWIAK, R., K. FRISTON et J. C. MAZZIOTTA (1997), *Human Brain Function*. Academic Press Inc., Chapter 3: Spatial Transformation of images.
- FREEBOROUGHT, P. A. et N. C. FOX (1998), « MR Image Texture Analysis Applied to the Diagnosis and Tracking of Alzheimer's Disease », *IEEE Transactions on Medical Imaging* 17(3), pp. 475--479.
- GALLOWAY, M. M. (1975), « Texture Analysis Using Gray Level Run Lengths », *Computer Graphics and Image Processing* 4, pp. 172--179.
- GEMAN, S. et D. GEMAN (1984), « Stochastic Relaxation, Gibbs distribution, and Bayesian Restoration of images », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 6(6), pp. 721--741.
- GONZALEZ, R. C. et R. E. WOODS (1992), *Digital Image Processing*, Reading, Mass.: Addison-Wesley.
- GORIS, M., S. BOUDIER et P. BRIANDET (1986), « Interrogation and Display of Single Photon Emission Tomography Data as Inherently Volume Data », *American Journal of Physiology Imaging* 1, pp. 168--180.
- GOTLIEB, C. C. et H. E. KREYSZIG (1990), « Texture Descriptors Based on Co-occurrence Matrices », *Computer Vision, Graphics, and Image Processing* 51, pp. 70--86.
- GREENSPAN, H., R. GOODMAN, R. CHELLAPPA et C. ANDERSON (1994), « Learning Texture Discrimination Rules in a Multiresolution System », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 16(9), pp. 894--901.
- HAND, D. J. (1981), *Discrimination and Classification*, New York: John Wiley and Sons.
- HARALICK, R. M. et K. SHANMUGAM (1973), « Computer Classification of Reservoir Sandstones », *IEEE Transactions on Geoscience and Electronics* 11, pp. 171--177.

- HARALICK, R. M., K. SHANMUGAM et I. DINSTEIN (1973), « Textural Features for Image Classification », *IEEE Transactions on Systems, Man, and Cybernetics* 3(6), pp. 610--621.
- HARALICK, R. M. et L. G. SHAPIRO (1992), *Computer and Robot Vision*, Volume 1, Reading, Mass.: Addison-Wesley.
- HASSNER, M. et J. SKLANSKY (1980), « The Use of Markov Random Fields as Models of Texture », *Computer Graphics Image Processing* 12, pp. 357--370.
- HEBB, D. O. (1949), *The organization of behavior: A Neuropsychological Theory*, New York: John Wiley and Sons.
- HECKBERT, P. (1997), « Images Designed as Web Page Backgrounds », <http://www.nepthys.com/textures/>.
- ISING, E. (1924), *Beitrag zur Theorie des Ferro- und Paramagnetismus*, Thèse de doctorat, Universität Hamburg.
- JASZCZAK, R. J., R. E. COLEMAN et C. B. LIM (1980), « SPECT: Single Photon Emission Computed Tomography », *IEEE Transactions on Nuclear Science* 27, pp. 1137--1153.
- JULESZ, B. (1962), « Visual Pattern Discrimination », *IRE Transactions on Information Theory* 8, pp. 84--92.
- JULESZ, B. (1975), « Experiments in the Visual Perception of Texture », *Scientific American* 232, pp. 2--11.
- KARAYIANNIS, Y. A. et T. STOURAITIS (1995), « Texture Classification using the Fractal Dimension as Computed in a Wavelet Decomposed Image », *IEEE Workshop on Nonlinear Signal and Image Processing* 20(22), pp. 186--189.
- KEYES, J. W. (1982), « Perspectives on Tomography », *Journal of Nuclear Medicine* 23, pp. 633--640.
- LAROUSSE (1981), *Larousse en trois volumes*, Paris, France: Librairie Larousse.
- MACLEOD, M. et OTHERS (1988), « Technetium-99m-HMPAO SPECT in Diagnosis of Cerebral Barotrauma », *British Journal of Radiology* 61, pp. 1106--1109.
- MALLAT, S. G. (1989), « A Theory for Multiresolution Signal Decomposition: The Wavelet Representation », *IEEE Transaction on Pattern Analysis and Machine Intelligence* 11(7).
- MANDELBROT, B. B. (1982), *Fractal Geometry of Nature*, San Francisco: Freeman.
- MARR, D. et E. HILDRETH (1980), « Theory of Fast Detection », *Proceedings of the Royal Society of London* 207, pp. 187--217.
- MCCULLOCH, W. S. et W. H. PITTS (1943), « A Logical Calculus of the Ideas Imminent in Nervous Activity », *Bulletin of Mathematical Biophysics* 5, pp. 115--133.
- MINOSHIMA, S., K. L. BERGER, K. S. LEE et M. A. MINTUN (1992), « An Automated Method for Rotational Correction and Centering

- of Three-Dimensional Functional Brain Images », *Journal of Nuclear Medicine* 33(8), pp. 1579--1585.
- MODESTINO, J. W., R. W. FRIES et A. VICKERS (1981), « Texture Discrimination Based Upon an Assumed Stochastic Texture Model », *IEEE Transaction on Pattern Analysis and Machine Intelligence* 3(5), pp. 557--580.
- NOUMEIR, R. (1994), *La reconstruction SPECT par la maximisation de la vraisemblance*, Thèse de doctorat, Université de Montréal, École Polytechnique, Canada.
- OHANIAN, P. P. et R. C. DUBES (1992), « Performance Evaluation for Four Classes of Textural Features », *Pattern Recognition* 25(8), pp. 819--833.
- PATTERSON, J. et D. J. WYPER (1997), « Basis of SPECT », in *SPECT Imaging of the Brain*, Dordrecht: Kluwer Academic Publisher,
- PELEG, S., J. NAOR, R. HARTLEY et D. AVNIR (1984), « Multiple Resolution Texture Analysis and Classification », *IEEE Transaction on Pattern Analysis and Machine Intelligence* 6(4), pp. 518--523.
- PENTLAND, A. P. (1984), « Fractal-Based Description of Natural Scenes », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 6(6), pp. 661--674.
- PENTLAND, A. P. (1986), « Shading into Texture », *Artificial Intelligence* 29, pp. 147--170.
- POSTAIRE, J. G. (1987), *De l'image à la décision*, Paris: Bordas.
- PRATT, W. K. (1978), *Digital Image Processing*, New York: Wiley-Interscience.
- REUZÉ, P. (1995), *Analyse d'images de résonance magnétique: Application à la segmentation des vaisseaux et à la caractérisation des textures*, Thèse de doctorat, Université de Rennes I, France.
- RIGAUT, J. P. (1988), « Automated Image Segmentation by Mathematical Morphology and Fractal Geometry », *Journal of Microscopy* 150(1), pp. 21--30.
- ROGER, T. et OTHERS (1996), « Decompression Illness in Sports Divers Detected with Technetium-99m-HMPAO SPECT and Texture Analysis », *Journal of Nuclear Medicine* 37(7), pp. 1154--1158.
- ROSENBLATT, F. (1962), *Principles of Neurodynamics: Perceptrons and Theory of Brain Mechanisms*, Washington: Spartan.
- ROUSSIN, E. (1993), *Analyse de l'impact de diverses méthodes de traitement d'image sur la quantification des radiotraceurs en médecine nucléaire*, Mémoire de maîtrise, Université de Montréal.
- RUMELHART, D. E., G. E. HINTON et R. J. WILLIAMS (1986), « Learning Internal Representations by Error Propagation », in

- Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, pp. 318--362.
- SARKAR, N. et B. B. CHAUDHURI (1992), « An Efficient Approach to Estimate Fractal Dimension of Textural Images », *Pattern Recognition* 25(9), pp. 1035--1041.
- SMITH, G. M. (1998), *Image Texture Analysis using Zero Crossing Information*, Thèse de doctorat, The University of Queensland, Disponible à <http://www.cssip.elec.uq.edu.au/staff/smith.html>.
- SPRAWLS, P. (1981), *The Physics and Instrumentation of Nuclear Medicine*, Baltimore, MA: University Park Press.
- STAFF, R. et OTHERS (1995), « Texture Analysis of Divers Brains Using Technetium-99m-HMPAO SPECT », *Nuclear Medicine Communications* 16, pp. 438--442.
- STOLLNITZ, E. J., T. D. DEROSE et D. H. SALESIN (1995), « Wavelets for Computer Graphics: A Primer, Part 1 », *IEEE Computer Graphics and Applications*, pp. 76--84.
- TAMURA, H. (1978), « Textural Features Corresponding to Visual Perception », *IEEE Transactions on Systems, Man, and Cybernetics* 8(6), pp. 460--472.
- VAPNIK, V. N. (1998), *Statistical Learning Theory*, New York: John Wiley and Sons.
- VENOT, A., J. LEBRUCHEC et J. ROUCAYROL (1984), « A New Class of Similarity Measures for Robust Image Registration », *Comput. Vis. Graph. Image Process.* 28, pp. 176--184.
- VICKERS, A. L. et J. W. MODESTINO (1982), « A Maximum Likelihood Approach to Texture Classification », *IEEE Transactions on Pattern Analysis and Machine Intelligence* 4(1), pp. 61--68.
- WALKER, R. F. (1996), « Cervical Cell Classification via Co-Occurrence and Markov Random Field Features », <http://www.cssip.elec.uq.oz.au/staff/walker.html>.
- WELLCOME DEPARTMENT OF COGNITIVE NEUROLOGY (1999), *Statistical Parametric Mapping*, <http://www.fil.ion.bpmf.ac.uk/spm/>.
- WESZKA, J. S., C. R. DYER et A. ROSENFELD (1976), « A Comparative Study of Texture Measures for Terrain Classification », *IEEE Transactions on Systems, Man, and Cybernetics* SMC-6(4), pp. 269--285.
- WILMSHURST, P. et OTHERS (1993), « Cerebral Perfusion Deficits in Divers with Neurological Decompression Illness », *Nuclear Medicine Communications* 14(177).
- ZHANG, T. (1996), « Issues in Texture Feature Classification and Segmentation », Unpublished document, available at <http://www.stanford.edu/class/cs328b/www/papers/zhang/zhang.html>.