



# UNIVERSITÉ FRANÇOIS RABELAIS DE TOURS



École Doctorale Santé, Sciences, Technologies  
Laboratoire d'Informatique (EA 2101)  
Équipe Reconnaissance des Formes et Analyse d'Images

**THÈSE** présentée par :

**Ludovic PAULHAC**

soutenue le : 24 novembre 2009

pour obtenir le grade de : Docteur de l'université François - Rabelais

Discipline/ Spécialité : Informatique

**Outils et méthodes d'analyse d'images 3D texturées : Application  
à la segmentation des images échographiques**

BOLON Philippe	Examineur	Professeur, LISTIC - Polytech Savoie
GREGOIRE Jean-Marc	Examineur	Ingénieur de Recherche, INSERM - Tours
MAKRIS Pascal	Examineur	Maître de conférences, Université François Rabelais de Tours
RAMEL Jean-Yves	Directeur	Professeur, Université François Rabelais de Tours
REVENU Marinette	Examineur	Professeur, ENSI de Caen
VINCENT Nicole	Rapporteur	Professeur, Université Paris Descartes
VRAY Didier	Rapporteur	Professeur, INSA de Lyon



# Remerciements

Je tiens à remercier Jean-Yves Ramel et Pascal Makris pour leur encadrement de qualité et pour leur disponibilité. J'ai pu mener avec eux de nombreuses discussions enrichissantes qui m'ont guidé et permis de mener à bien cette thèse.

Je remercie Jean-Marc Grégoire pour son aide et ses explications concernant le domaine médical et les modalités d'acquisition des images échographiques 3D.

Merci également à Philippe Bolon, Marinette Revenu, Nicole Vincent et Didier Vray de m'avoir fait l'honneur d'être rapporteur et examinateur de mon jury.

Je tiens à remercier mes collègues de l'équipe RFAI et, plus généralement, de l'école Polytechnique et du Laboratoire d'Informatique de Tours. Durant ces 3 ans, j'ai pu grâce à eux passer de très bon moments.

Je remercie aussi mes étudiants de Polytech'Tours avec qui j'ai découvert l'enseignement tout au long de ma thèse.

Enfin je remercie toutes les personnes qui me sont chères pour leur soutien quotidien. J'ai une pensée toute particulière pour les membres de ma famille qui m'ont encouragé dans mes études et sans qui je n'aurais jamais pu soutenir cette thèse. Ce travail leur est dédié.

## REMERCIEMENTS

---

# Résumé

Le travail présenté dans cette thèse s'inscrit dans le domaine de l'analyse d'images texturées et plus particulièrement d'images 3D (ensembles de voxels). Pour ces dernières, les difficultés d'analyse sont principalement dues à la très grande quantité d'informations à prendre en compte et à traiter, ce qui rend inefficaces les méthodes dédiées aux images 2D. De plus, outre le faible nombre de travaux proposant des méthodes réellement 3D, la majeure partie des méthodes d'analyse de textures existantes n'ont pas une applicabilité très étendue et sont incapables d'identifier certaines classes de textures.

En comparaison, le système visuel humain s'adapte à tous types de textures, même en présence d'un contexte défavorable. Les textures sont donc facilement discernées par l'humain, mais très difficiles à définir sous forme d'un modèle mathématique unique offrant une description purement quantitative.

Partant de l'hypothèse qu'il est plus pertinent de décrire une texture avec des adjectifs qualificatifs (description qualitative) plutôt qu'avec un modèle mathématique unique, nous avons choisi dans un premier temps de définir un nouvel ensemble de descripteurs de textures permettant une caractérisation qualitative des textures contenues dans les images 3D. Il est difficile de produire une définition consensuelle du terme "texture". Néanmoins, la première contribution de cette thèse est la proposition d'un nouvel ensemble de caractéristiques de textures solides construit à partir de propriétés de textures facilement appréhendable par l'utilisateur humain. Ces nouveaux descripteurs permettent entre autres de décrire des propriétés texturales telles que la directionnalité, la rugosité et le contraste. La deuxième contribution de cette thèse correspond aux techniques multi-résolutions que nous proposons d'exploiter pour extraire ces caractéristiques des images 3D, techniques basées sur une décomposition en ondelette couplée à une analyse des composantes géométriques contenues dans les représentations obtenues. Enfin, le système de segmentation interactif d'images échographiques 3D de la peau, intégrant nos descripteurs de textures solides, couplé à un mécanisme de clustering et à une interface homme-machine adaptée constitue, selon nous, une troisième contribution. Ce système nous a permis de valider expérimentalement la robustesse et la généralité de nos propositions, et intéresse aujourd'hui de nombreux acteurs du monde de la santé (médecins, dermatologues, industriels, ...).

**Mots clés :** Textures solides, caractéristiques de textures, multirésolution, segmentation d'images échographiques 3D, système interactif.



# Abstract

This work deals with the domain of textured images analysis more specifically with 3D images (set of voxels). The difficulties to process volumetric data is due to the quantity of considered information that make ineffective 2D methods. Moreover, beyond the few numbers of methods real 3D, the major part of texture analysis methods have not a large applicability and are unable to identify some classes of texture.

In comparison, the human visual system adapts to all types of textures even if the context is unfavorable. Textures are easily discriminated by human, nevertheless it is very difficult to define them using a single mathematic model. Supposing that it is more relevant to describe a texture using qualifier adjectives than using a single mathematic model, we choose to define a new set of texture descriptors that allows us to have a qualitative characterisation of 3D images. It is difficult to produce a consensual definition of the term "texture". However, the first contribution of this thesis is the proposition of a set of new solid texture descriptors built using texture properties easily understandable by humans. These new attributes can quantify textural properties such as the directionality, the roughness, the contrast, the regularity but also information on shapes. The second contribution of this thesis is the proposal of a multiresolution system which associates a discrete wavelet transform and an analysis of geometric components content inside the obtained representations. Finally, the last contribution is the interactive system of segmentation of 3D ultrasound images which use our solid texture descriptors coupled with a clustering mechanism and an man-aided interface. With this system, the hardiness and the genericity of our propositions have been experimentally validated and currently it presents a big interest for several actors in the medical world (doctors, dermatologists, industrialists, etc.).

**Keywords :** Solid textures, texture features, multiresolution, segmentation of 3D ultrasound images, interactive system.

## ABSTRACT

---



# Table des matières

<b>Table des matières</b>	<b>9</b>
<b>Liste des tableaux</b>	<b>13</b>
<b>Table des figures</b>	<b>15</b>
<b>Introduction</b>	<b>19</b>
<b>1 Méthodes d'analyse de textures 2D et solides</b>	<b>23</b>
1.1 Notion de textures . . . . .	23
1.1.1 Les familles de textures . . . . .	23
1.1.2 Comment définir une texture ? . . . . .	25
1.1.3 Perception visuelle des textures . . . . .	25
1.1.4 Propriétés de perception des textures . . . . .	27
1.2 Méthodes d'extraction de caractéristiques de textures . . . . .	28
1.2.1 Les méthodes basées sur une analyse des motifs . . . . .	29
1.2.2 Les méthodes fréquentielles . . . . .	39
1.2.3 Les méthodes basées sur un modèle . . . . .	50
1.2.4 Les méthodes basées sur une analyse spatiale et statistique des intensités de niveau de gris . . . . .	58
1.2.5 Vers une caractérisation plus visuelle des textures . . . . .	64
1.3 Caractérisation des textures solides . . . . .	67
1.4 Méthodes d'exploitation des caractéristiques de textures . . . . .	70
1.4.1 Méthodes de classification . . . . .	70
1.4.2 Méthodes de segmentation de textures . . . . .	71
1.5 Comparaison de méthodes d'analyse de textures . . . . .	72
1.6 Modélisation d'un système de reconnaissance de textures . . . . .	74
1.7 Conclusion . . . . .	77
<b>2 Caractérisation visuelle de textures volumétriques</b>	<b>81</b>

## TABLE DES MATIÈRES

---

2.1	Proposition de caractéristiques de textures compréhensibles par un être humain	81
2.2	Caractérisation géométrique des textures . . . . .	85
2.2.1	Caractéristiques obtenues par étude des composantes connexes 3D . . . . .	88
2.2.2	Méthodes de génération de composantes connexes 3D . . . . .	89
2.3	Caractérisation fréquentielle des textures volumétriques . . . . .	99
2.3.1	Estimation de la rugosité . . . . .	100
2.3.2	Caractérisation de l'orientation . . . . .	100
2.4	Mesure statistique pour le contraste . . . . .	101
2.5	Expérimentations psychologiques . . . . .	101
2.5.1	Comparaison du classement humain et du classement obtenu à partir de nos méthodes de calcul . . . . .	103
2.6	Conclusion . . . . .	105
<b>3</b>	<b>Évaluation quantitative des descripteurs qualitatifs proposés</b>	<b>107</b>
3.1	Base de textures solides pour l'évaluation de méthodes de classification et de segmentation . . . . .	107
3.1.1	Méthodes de synthèse utilisées . . . . .	108
3.1.2	Organisation de la base d'images . . . . .	112
3.2	Extension 3D de la méthode des motifs binaires (LBP) . . . . .	114
3.3	Expérimentations en classification . . . . .	117
3.3.1	Évaluation d'algorithmes de classification d'images . . . . .	117
3.3.2	Évaluation de nos descripteurs en classification . . . . .	118
3.4	Expérimentations en segmentation . . . . .	122
3.4.1	Évaluation d'algorithmes de segmentation d'images . . . . .	122
3.4.2	Évaluation de nos descripteurs . . . . .	123
3.5	Quelques mots sur les temps de calcul et la normalisation des données . . . . .	129
3.6	Conclusion . . . . .	130
<b>4</b>	<b>Segmentation d'images échographiques 3D</b>	<b>135</b>
4.1	Caractéristiques et modes d'acquisition des images ultrasonores 3D . . . . .	135
4.1.1	Sonde d'acquisition 3D . . . . .	136
4.1.2	Images échographiques 2D et 3D . . . . .	136
4.1.3	Images ultrasonores de la peau . . . . .	137
4.2	Méthodes de segmentation classiques . . . . .	138
4.2.1	<i>A priori</i> sur le bruit . . . . .	138
4.2.2	Utilisation de contraintes de forme . . . . .	139
4.2.3	Analyse des textures . . . . .	139
4.3	Notre proposition . . . . .	140

## TABLE DES MATIÈRES

---

4.3.1	Architecture du système proposé et interactivité . . . . .	141
4.3.2	Résultats obtenus et comparaison aux autres méthodes . . . . .	142
4.4	Conclusion . . . . .	145
	<b>Conclusion</b>	<b>155</b>
	<b>Annexes</b>	<b>161</b>
A	Attributs de textures d'Haralick	161
B	Exemple de segmentation d'images ultrasonores de la peau	165
C	Principaux composants de la DTD utilisée dans la construction de la base de textures solides	171
D	Questionnaire sur le classement de textures volumétriques	173
	<b>Bibliographie</b>	<b>177</b>

## TABLE DES MATIÈRES

---

# Liste des tableaux

1.1	Tableau des caractéristiques calculées sur les polygones de Voronoï . . . . .	37
2.1	Tableau de caractéristiques calculées à partir d'une binarisation Niblack . .	90
2.2	Tableau de caractéristiques calculées après binarisation globale . . . . .	92
2.3	Tableau de caractéristiques calculées à partir de plusieurs binarisations . . .	94
2.4	Tableau de caractéristiques calculées sur différentes zones d'intérêts. . . . .	96
2.5	Degré de correspondance des caractéristiques de textures à partir des différents classements humains et ceux obtenus à partir de nos méthodes de calculs pour la résolution 1 . . . . .	104
2.6	Degré de correspondance des caractéristiques de textures à partir des différents classements humains et ceux obtenus à partir de nos méthodes de calculs pour la résolution 2 . . . . .	104
2.7	Degré de corrélation obtenu à partir des classements informatiques de chaque caractéristique à la résolution 1 . . . . .	104
2.8	Degré de corrélation obtenu à partir des classements humains de chaque caractéristique . . . . .	105
3.1	Pourcentage des motifs uniformes . . . . .	115
3.2	Pourcentage de reconnaissance avec les 14 caractéristiques d'Haralick sur la base de test sans bruit (95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . .	120
3.3	Pourcentage de reconnaissance avec les 14 caractéristiques d'Haralick sur la base de test contenant à la fois des images normales et bruitées (95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . .	120
3.4	Pourcentage de reconnaissance avec la méthode LBP 3D sur la base de test sans bruit ( $P'$ caractéristiques, 95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . .	120
3.5	Pourcentage de reconnaissance avec la méthode LBP 3D sur la base de test contenant à la fois des images normales et bruitées ( $P'$ caractéristiques, 95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . .	120

LISTE DES TABLEAUX

---

3.6 Pourcentage de reconnaissance avec la méthode LBP 2D sur les deux bases de test ( $P$  caractéristiques, 95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . . 120

3.7 Pourcentage de reconnaissance avec notre méthode HUF sur la base de test contenant des images normales ( $7\beta$  caractéristiques, 95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . . 121

3.8 Pourcentage de reconnaissance avec notre méthode HUF sur la base de test contenant à la fois des images normales et bruitées ( $7\beta$  caractéristiques, 95 classes, 4 images d'apprentissage et 6 images de test par classe). . . . . 121

3.9 Evaluation de segmentations de textures solides contenant deux classes à partir de la mesure générique d'anomalie. . . . . 130

3.10 Evaluation de segmentations de textures solides contenant trois classes à partir de la mesure générique d'anomalie. . . . . 131

3.11 Evaluation de segmentations de textures solides contenant quatre classes à partir de la mesure générique d'anomalie. . . . . 132

3.12 Temps d'exécution des méthodes HUF, GLCM 3D et LBP 3D pour segmenter une image 3D de taille  $128^3$ . . . . . 132

4.1 Textures dans les images ultrasonores de la peau . . . . . 141

# Table des figures

1.1	Exemple de familles de textures : [a-d] textures déterministes, [e-h] textures observables, [i-l] textures stochastiques . . . . .	24
1.2	Images contenant des textures de second ordre statistique identiques . . . . .	26
1.3	Information sur une texture selon plusieurs régionalités . . . . .	27
1.4	Représentation d'une texture selon plusieurs résolutions . . . . .	28
1.5	Construction des unités de textures en croix et en diagonale avec un voisinage de $3^2$ pixels. . . . .	32
1.6	Construction d'un motif binaire et calcul du code LBP . . . . .	33
1.7	Représentation du pixel central $g_c$ et de son voisinage $g_p$ . . . . .	33
1.8	Exemples de motifs uniformes et non-uniformes . . . . .	34
1.9	A gauche le motif original et à droite le motif requantifié avec $N = 9$ . . . . .	36
1.10	Représentation d'une suite de textures binaires 2D construite à partir de seuils de binarisation évoluant de façon croissante. . . . .	38
1.11	Représentation du filtre de Gabor et de ses paramètres dans le domaine fréquentiel . . . . .	42
1.12	Décomposition en ondelette d'un signal 1D . . . . .	45
1.13	Décomposition en ondelette d'une image 2D . . . . .	46
1.14	Décomposition en paquets d'ondelette sur un signal 1D . . . . .	47
1.15	Les 13 filtres du banc de filtre de Schmid . . . . .	48
1.16	Le banc de filtres de Leung-Malik est composé de 48 filtres avec des filtres frontières, tâches et bandes selon plusieurs résolutions et orientations . . . . .	49
1.17	Banc de filtres MR8 composé de 38 filtres à la fois isotropiques et anisotropiques . . . . .	50
1.18	Représentation d'un système de voisinage d'ordre 2 . . . . .	51
1.19	Ensemble de cliques pour un système de voisinage d'ordre 2 (8-connexe) . . . . .	51
1.20	Construction de la courbe de Koch . . . . .	56
1.21	Fonction d'auto-corrélation calculée à partir du spectre de puissance d'une texture volumétrique . . . . .	60
1.22	Exemple de fonctions d'auto-corrélation . . . . .	61

TABLE DES FIGURES

---

1.23	Exemple de matrices de cooccurrences de niveaux de gris sur des textures de Brodatz . . . . .	63
1.24	Illustration sur différents types de représentations des textures . . . . .	68
1.25	Système de reconnaissance de textures . . . . .	75
2.1	Représentation d’images extrêmes pour chacune des caractéristiques proposées. . . . .	84
2.2	Schéma représentatif du calcul des caractéristiques proposées . . . . .	86
2.3	Ce schéma présente de gauche à droite : une image ultrasonore 3D en niveau de gris, une version binaire de cette même image, et deux représentations 3D de composantes connexes, extraites à partir de deux images binarisées à des seuils différents. . . . .	88
2.4	Calcul de caractéristiques (tableau 2.1) sur différentes zones d’intérêts après binarisation avec la méthode de Niblack . . . . .	91
2.5	Calcul de caractéristiques (tableau 2.2) sur différentes zones d’intérêts après une binarisation globale . . . . .	92
2.6	Zones d’intérêts utilisées pour calculer les caractéristiques de textures présentées tableaux 2.3 et 2.4 . . . . .	95
2.7	Histogramme du nombre d’individus par classe après application de l’algorithme <i>k-means</i> sur des textures volumétriques pour différentes valeurs de <i>k</i> . . . . .	99
2.8	Ensemble des textures solides utilisées dans nos expérimentations psychologiques . . . . .	102
3.1	Exemple de construction d’une texture solide à partir de la méthode d’interpolation (méthode 1) . . . . .	109
3.2	Textures solides construites à partir de la 2 <sup>ème</sup> méthode . . . . .	110
3.3	Exemple de textures solides avec des textures à l’intérieur et à l’extérieur des motifs géométriques (méthode 4) . . . . .	110
3.4	Exemple de textures solides construites à partir de la transformée de Fourier (méthode 3) . . . . .	111
3.5	[a-c] Textures solides avec rotation aléatoire, [d-e] Deux textures floutées, [f-g] Deux textures bruitées, [h-i] Deux textures solides sous-échantillonnées . . . . .	113
3.6	Représentation d’un motif local binaire 3D (S=9, R=2, P=16) . . . . .	116
3.7	Exemple de deux motifs LBP 3D ayant le même code LBP ( $LBP_{P',R}^{riu2} = 12$ ). Ici, la valeur des vertex en noir est égale à 1 alors que la valeur des autres vertex est de 0. . . . .	116
3.8	Un exemple de graphe ROC . . . . .	119
3.9	Exemple d’une image 3D contenant 3 textures solides avec ses vérités terrains associées . . . . .	124
3.10	Images de textures volumétriques : [a-e] 2 classes de textures, [f-j] 3 classes de textures, [k-o] 4 classes de textures . . . . .	126



TABLE DES FIGURES

---

3.11	Schéma de segmentation multirésolution . . . . .	127
3.12	Exemple de segmentation avec $K = 10$ et en fusionnant jusqu'à $K = 2$ . . . . .	128
4.1	Exemple d'image 3D de la peau obtenue avec l'échographe 20 MHz DERM-CUP (Alys Medical France) . . . . .	137
4.2	Schéma représentatif de l'utilisation de notre logiciel . . . . .	143
4.3	Interfaces du prototype logiciel mis en place pour la segmentation d'images échographiques 3D. . . . .	144
4.4	Visualisation des différentes couches de la peau obtenues à partir d'une image segmentée. . . . .	146
4.5	Image ultrasonore 3D de la peau contenant un nævus. . . . .	147
4.6	Segmentation de l'image figure 4.5 obtenue avec la méthode HUF . . . . .	147
4.7	Maillage construit à partir de l'image segmentée figure 4.6 (méthode HUF). . . . .	148
4.8	Segmentation de l'image figure 4.5 obtenue avec la méthode GLCM 3D. . . . .	148
4.9	Maillage construit à partir de l'image segmentée figure 4.8 (GLCM 3D). . . . .	149
4.10	Segmentation de l'image figure 4.5 obtenue avec la méthode LBP 3D. . . . .	149
4.11	Image ultrasonore 3D de la peau contenant un histiocytofibrome . . . . .	150
4.12	Segmentation de l'image figure 4.11 obtenue avec la méthode HUF. . . . .	150
4.13	Maillage construit à partir de l'image segmentée figure 4.12 (méthode HUF). . . . .	151
4.14	Segmentation de l'image figure 4.11 obtenue avec la méthode GLCM 3D. . . . .	151
4.15	Maillage construit à partir de l'image segmentée figure 4.14 (GLCM 3D). . . . .	152
4.16	Segmentation de l'image figure 4.11 obtenue avec la méthode LBP 3D. . . . .	152
4.17	Ensemble de segmentations d'une image échographique 3D avec la méthode HUF (localisation de tendons). . . . .	153
B.1	Image ultrasonore 3D de la peau contenant un nævus. . . . .	165
B.2	Segmentation de l'image figure B.1 obtenue avec la méthode HUF. . . . .	166
B.3	Maillage construit à partir de l'image segmentée figure B.2 (méthode HUF). . . . .	166
B.4	Image ultrasonore 3D de la peau contenant un histiocytofibrome. . . . .	167
B.5	Segmentation de l'image figure B.4 obtenue avec la méthode HUF. . . . .	167
B.6	Maillage construit à partir de l'image segmentée figure B.5 (méthode HUF). . . . .	168
B.7	Image ultrasonore 3D de la peau contenant un mélanome. . . . .	168
B.8	Segmentation de l'image figure B.7 obtenue avec la méthode HUF. . . . .	169
B.9	Maillage construit à partir de l'image segmentée figure B.8 (méthode HUF). . . . .	169

## TABLE DES FIGURES

---

# Introduction

Le développement récent des technologies d'imagerie médicale 3D ouvre de nouvelles perspectives très prometteuses dans le domaine de la santé et du bien-être. Des efforts considérables ont été consentis et continuent à être produits pour concevoir des systèmes d'acquisition toujours plus précis et performants (IRM, échographie 3D, etc.). Ces dispositifs commencent à se multiplier dans les hôpitaux et chez les médecins. Les files d'attente pour l'accès à ce type d'examen sont toujours de plus en plus longues ce qui prouve l'intérêt de ce type d'outils. D'un autre côté, il semble que les techniques d'aide à l'exploitation des données 3D suscitent moins d'intérêt et évoluent beaucoup moins rapidement. Peut-être est-ce dû au fait que l'on a cru qu'il suffirait de considérer les images 3D uniquement comme des successions d'images 2D pour les interpréter ? Il nous semble que cela n'est pas le cas et que d'énormes progrès peuvent encore être obtenus en considérant les images 3D avec leur complexité propre. Cela nécessite le développement de modèles spécifiques intégrant des connaissances multiples et capables de gérer des quantités d'information énormes. Nous avons la chance, à Tours, de bénéficier d'un environnement propice à la réalisation d'avancées majeures dans ce domaine puisque les principaux acteurs de l'imagerie 3D sont présents à proximité (CHRU de Tours, l'équipe 5 de l'UMR INSERM U390, IFR 135 d'imagerie fonctionnelle, pôle de compétitivité Cosmetic Vallée, etc.). Ainsi, l'un des objectifs de ce travail est de faire naître une synergie entre tous ces acteurs en se focalisant sur la mise au point d'outils informatiques d'aide à l'analyse de données 3D plutôt que sur la conception de dispositifs matériels. L'un des challenges est alors de susciter la collaboration de personnes d'origines pluridisciplinaires pour contribuer à la mise au point d'un système efficace d'analyse d'images 3D et plus particulièrement d'images ultrasonores. Ces dernières présentent de nombreux intérêts dont les deux facteurs essentiels sont d'une part, le coût du matériel et d'autre part, les effets non invasifs inhérents à la technologie employée. Ces deux atouts sont néanmoins contrecarrés par une grande difficulté d'interprétation de leur contenu. En effet, ces images contiennent un certain nombre d'artefacts et de variations liés aux phénomènes de propagation des ultrasons qui compliquent le processus de segmentation. Dans [Noble et Boukerroui, 2006], les auteurs présentent les facteurs essentiels pour mettre en place des outils complets et robustes pour la segmentation d'images ultrasonores. Parmi eux, nous retrouvons les méthodes d'analyse de textures qui sont très répandues dans les applications 2D et beaucoup moins dans le traitement d'images 3D. Outre le nombre important de méthodes, les résultats restent encore peu précis et les solutions apportées se focalisent souvent sur une problématique donnée, dédiée à un type d'application. Il serait pourtant intéressant de développer des outils génériques, utilisables de façon automatique ou semi-automatique, qui permettraient un panel d'utilisation beaucoup plus important

mais aussi une interactivité mieux adaptée aux différentes situations.

Ainsi, le travail que nous présentons s'inscrit dans le domaine des images 3D texturées aussi connues sous le nom de textures solides ou volumétriques. Ces dernières comportent des volumes de données et d'informations très importants qui rendent difficile, et dans certains cas inefficace, l'exploitation de méthodes dédiées aux images 2D. En effet, même s'il reste possible pour une méthode d'analyse de textures 2D de traiter une donnée volumétrique au travers des différentes coupes 2D qui la composent, les informations ainsi obtenues seront biaisées de par le voisinage considéré qui fait abstraction de la notion de profondeur. Un exemple évident concerne la caractéristique de directionnalité : comment mettre en place un système permettant de détecter une direction principale dans un contexte 3D avec une méthode basée 2D ? Les approches volumétriques permettent de considérer l'ensemble des directions alors que les méthodes 2D sont aveugles à l'agencement et la répartition des voxels entre les couches 2D.

Outre le faible nombre de travaux proposant des méthodes réellement 3D, la majeure partie des méthodes d'analyse de textures n'ont pas une applicabilité très étendue et sont incapables d'identifier certaines classes de textures. Ce n'est pas le cas du système visuel humain qui s'adapte à tous types de textures même en présence d'un contexte défavorable. Donner une définition générale du terme "texture" est connu comme quelque chose de difficile. En effet, une texture fait apparaître des notions abstraites qu'il est complexe de définir correctement de façon théorique. Afin de décrire une texture, les humains utilisent plutôt des notions qualitatives agrémentées par un ensemble d'adjectifs qualificatifs (rugueux, granuleux, contrasté, etc.). Il paraît donc très difficile de définir une texture sous forme d'un unique modèle mathématique produisant une description purement quantitative.

Partant de l'hypothèse qu'il semble plus pertinent de décrire une texture avec des adjectifs qualificatifs (description qualitative) plutôt qu'avec un modèle mathématique unique, nous avons choisi dans un premier temps de définir un nouvel ensemble de descripteurs de textures permettant une caractérisation qualitative des textures contenues dans les images 3D. Bien que conscient de la difficulté à produire une définition consensuelle du terme texture, la première contribution de cette thèse est donc la proposition d'un nouvel ensemble d'attributs dédié aux textures solides et construit à partir de propriétés de textures facilement appréhendables par l'utilisateur humain. Ces nouveaux descripteurs permettent entre autre de décrire des propriétés texturales telles que la directionnalité, la rugosité ou bien le contraste.

La deuxième contribution de cette thèse correspond aux techniques multi-résolutions que nous proposons d'exploiter pour extraire ces caractéristiques des images 3D. L'idée principale est d'accepter le fait qu'une seule approche (fréquentielle, statistique, fractale, etc.) n'est pas suffisante pour garantir une forte généralité et robustesse. Nous proposons donc de coupler différentes méthodes avec notamment la décomposition en ondelettes et l'analyse de composantes géométriques contenues dans les représentations obtenues.

Bien évidemment, l'objectif initial de conception d'un système interactif de segmentation d'images échographiques 3D de la peau intégrant nos descripteurs de textures solides constitue, selon nous, une troisième contribution. Ce système, qui offre un degré d'adaptabilité et d'interaction important, nous a permis de valider expérimentalement la robustesse et la

généricité de nos propositions. Ce prototype intéresse aujourd'hui de nombreux acteurs du monde de la santé (médecins, dermatologues, industriels, ...).

Dans la première partie de cette thèse, nous nous intéressons aux méthodes "classiques" d'analyse de textures. Nous proposons une classification de ces méthodes selon les types d'informations qu'elles exploitent : les méthodes proposant une analyse basée sur l'extraction des motifs d'une texture ; les méthodes basées sur une analyse fréquentielle regroupant principalement la transformée de Fourier ; les filtres de Gabor et la transformée en ondelette ; les méthodes basées sur un modèle qui permettent l'introduction de connaissances *a priori* ; les méthodes proposant une analyse spatiale de l'intensité des niveaux de gris ; et enfin les méthodes calquées sur le système visuel humain. Nous passons également en revue les méthodes d'analyse de textures développées plus spécifiquement pour le traitement de textures volumétriques. Enfin, nous essayons de mettre en avant les points forts mais également les points faibles de chaque catégorie de méthodes répertoriée dans notre classification, et ceci afin de justifier les choix réalisés dans cette thèse.

Le deuxième chapitre présente les attributs de textures que nous proposons d'exploiter. Ces caractéristiques de textures sont adaptées aux images 3D et sont construites avec l'aide de méthodes réputées comme performantes. Nous exposons alors les méthodes choisies afin de les quantifier et d'en donner une bonne approximation. Chacun de ces descripteurs correspond à un adjectif qualificatif fréquemment utilisé par les humains afin de décrire les propriétés d'une texture. Nous nous attachons enfin à démontrer la forte correspondance entre les caractéristiques proposées et une qualification humaine des textures à travers une expérimentation psychologique.

Dans le troisième chapitre, nous évaluons les caractéristiques de notre méthode HUF (*Human Understandable Feature*) au travers de plusieurs expérimentations visant à produire des résultats quantitatifs. Pour cela, nous avons choisi des méthodes d'analyse de textures reconnues dans la littérature : les matrices de cooccurrence d'Haralick, qui sont une référence en analyse d'images, et la méthode des motifs binaires (LBP) qui est reconnue comme très performante et efficace en 2D. Une proposition pour étendre la méthode LBP à la 3D est également présentée et évaluée. Nous effectuons, dans un premier temps, des tests de classification puis, dans un deuxième temps, des tests de segmentation sur un ensemble de textures solides de synthèse que nous avons produit et mis à disposition des autres chercheurs. Dans les deux cas, les résultats présentés sont des évaluations quantitatives obtenues à partir de critères d'évaluations reconnus.

Le dernier chapitre décrit la façon dont nous exploitons les descripteurs de textures proposés afin de produire le système de segmentations d'images échographiques 3D de la peau voulu. Afin de situer l'intérêt de notre approche, nous faisons une brève présentation des modalités d'acquisition des images échographiques traitées. Un état de l'art détaillant les principales méthodes de segmentation habituellement appliquées sur ce type d'images complète cette partie. Les détails de notre système de segmentation sont ensuite décrits en insistant notamment sur les intérêts de la proposition que nous avons mis en place en collaboration avec des spécialistes en échographie 3D. Une comparaison avec d'autres

méthodes d'analyse de textures conclut ce chapitre plus applicatif.

En conclusion, nous proposons une synthèse concernant nos différentes contributions et nous discutons sur plusieurs perspectives possibles afin d'améliorer nos approches et de proposer de nouvelles voies de recherches.

# Chapitre 1

## Méthodes d'analyse de textures 2D et solides

L'analyse des textures est un sujet ancien de l'analyse d'image et de la vision par ordinateur. Les techniques existantes sont utilisées pour identifier une texture quelconque ou diviser une image texturée en plusieurs régions comportant des caractéristiques identiques. Nous les retrouvons dans plusieurs domaines d'application comme l'analyse de scènes et de vidéos, l'imagerie médicale, l'industrie etc. Les recherches en analyse de textures se divisent en trois grandes catégories : la classification, permettant de reconnaître une texture donnée ; la segmentation, ayant pour objectif d'identifier les différentes classes de textures dans une même image ; et la synthèse de textures qui peut être également utilisée pour la compression d'images. Différents types d'images comprenant les images binaires, en niveaux de gris et en couleurs sont concernés par ces outils d'analyse. Selon les données à traiter, les techniques d'analyse de textures peuvent varier. Pour analyser une texture couleur, il est possible d'utiliser une méthode standard d'analyse de textures en niveaux de gris sur chacun des canaux RGB, mais certains auteurs préfèrent la combinaison d'informations afin de traiter des entités simples [Shi et Funt, 2007]. Cette thèse traite plus particulièrement des méthodes d'analyse de textures en niveaux de gris. Dans cet état de l'art, nous présentons tout d'abord les notions et la terminologie essentielles concernant les textures et leur analyse, avec notamment une discussion sur les propriétés perceptuelles concernant les textures. Par la suite, nous passons en revue les principaux descripteurs de textures utilisés sur les images texturées 2D et 3D.

### 1.1 Notion de textures

#### 1.1.1 Les familles de textures

Dans la littérature, il est souvent question de plusieurs familles de textures avec notamment les textures déterministes, les textures stochastiques et les textures observables [Gool *et al.*, 1985] (figure 1.1) . Les textures déterministes se caractérisent par la répétition d'un motif géométrique aussi appelé "texton". Ce genre de textures peut donc facilement être synthétisé à partir d'un motif si on connaît son orientation et sa taille.

Au contraire, les textures stochastiques sont irrégulières. Elles obéissent à certaines lois statistiques et peuvent être considérées comme une réalisation d'un champ aléatoire bidimensionnel.

Une texture observable se décrit comme un mélange entre une texture stochastique et une texture déterministe. En effet, à l'intérieur de ce type de textures, nous pouvons trouver une répétition de motifs très similaires mais pas identiques.




FIG. 1.1 – Exemple de familles de textures : [a-d] textures déterministes, [e-h] textures observables, [i-l] textures stochastiques

Certains auteurs n'utilisent pas le vocabulaire précédent et préfèrent parler de textures structurées (macro-textures) ou de textures aléatoires (micro-textures) [Unser, 1995]. Les textures structurées ont pour caractéristique la répétition de primitives à intervalles réguliers. Parmi elles, nous pouvons différencier les textures parfaitement périodiques (textures déterministes) et les textures dont les primitives ont subi quelques transformations (textures observables). Les textures aléatoires (textures stochastiques) se distinguent par un aspect plus fin (sable, herbe, etc.). Il est difficile d'en isoler une primitive de base et d'identifier une fréquence de répétition.

Il existe une grande diversité de textures. Certains ouvrages mettent à disposition des textures avec différentes propriétés, très utiles pour tester les algorithmes et les mé-



thodes. Parmi ceux-ci, la base présentée dans [Brodatz, 1966] et la base Meastex (<http://www.texturesynthesis.com/meastex/meastex.html>) proposent des collections de textures naturelles 2D en niveaux de gris souvent utilisées pour tester les algorithmes d'analyse et de classification. Ces bases pourront nous servir d'exemples pour la génération de nouvelles images ou pour tester certaines de nos méthodes.

### 1.1.2 Comment définir une texture ?

Donner une définition précise du terme "texture" est quelque chose de difficile. Il en existe un grand nombre et [Coggins, 1983] nous en donne un panel dont voici quelques exemples :

- "Une région dans une image contient une texture constante si un ensemble de statistiques locales ou autres propriétés de la fonction image sont constantes, varient faiblement ou sont approximativement périodiques.[Sklansky, 1978]"
- "Une image texturée est décrite par le nombre et les types de ses primitives tonales ainsi que leurs orientations spatiales. Elle ne peut pas être analysée sans une vue de la primitive tonale de référence. Pour certaines surfaces ayant un ton de gris flouté, il existe une échelle telle que la texture est inexistante. Au fur et à mesure que la résolution augmente, on observe une texture fine puis une texture grossière.[Haralick, 1979]"

Dans sa thèse, [Unser, 1984] donne une définition perceptuelle de la texture :

- "Une texture est une région d'une image pour laquelle il est possible de définir une fenêtre de dimensions minimales, telle qu'une observation au travers de celle-ci se traduit par une perception (impression) visuelle identique pour toutes les translations possibles de cette fenêtre à l'intérieur de la région considérée."

Certaines de ces définitions décrivent les textures de façon perceptuelle, d'autres se focalisent plus sur une stabilité de mesures statistiques à l'intérieur d'une région ou sur la méthode de génération utilisée. La plupart d'entre elles ne sont pas satisfaisantes dans le sens où elles proposent une description soit trop générale et donc imprécise, soit trop restrictive pour s'adapter à la diversité des cas rencontrés. Une texture est donc quelque chose d'abstrait, difficile à définir quantitativement de façon précise. Cependant une texture peut presque toujours être décrite par des termes, des adjectifs souvent dépendants du domaine concerné (images médicales, images naturelles, matériaux, etc.) mais plus faciles à comprendre et donc plus faciles à manipuler.

### 1.1.3 Perception visuelle des textures

Julesz a étudié de façon poussée la perception visuelle des textures [Julesz, 1962, Julesz, 1971]. Afin de pouvoir différencier un ensemble de textures, il se concentre sur l'analyse des statistiques spatiales des niveaux de gris d'une image. Ses travaux se sont donc beaucoup orientés sur la comparaison de textures selon leur ordre statistique. Rappelons que les statistiques de premier ordre mesurent la probabilité d'observer un niveau de gris à un emplacement aléatoire d'une image alors que les statistiques du deuxième ordre déterminent la probabilité d'observer une paire de niveaux de gris selon une orientation et

une distance.

[Julesz, 1962] donne une description de la perception visuelle humaine des textures en affirmant qu'elle utilise les statistiques d'ordre 2 des niveaux de gris. Cependant des contre-exemples ont été trouvés par [Gagalowicz, 1983] et Julesz lui-même. En effet, il existe des textures ayant des moments d'ordres 1 et 2 identiques. De plus, les statistiques d'ordre 2 décrivent bien souvent des processus à distribution gaussienne ; or [Coroyer, 1996] montre l'aspect non-gaussien des textures naturelles. Malgré ces restrictions, les approches comme les matrices de cooccurrences [Haralick *et al.*, 1973, Haralick, 1979] sont encore très utilisées pour leurs simplicité de mise en oeuvre et leur bons résultats. Julesz affirme également qu'il est difficile de différencier deux textures si leurs statistiques de second ordre sont identiques. Dans la figure 1.2(a), nous avons deux régions texturées ayant un second ordre statistique identique et nous pouvons voir qu'il est très difficile de les discerner. Cependant la figure 1.2(b) présente deux textures de second ordre statistique identiques et les deux régions sont bien visibles.

Pour expliquer cela, Julesz propose la théorie des textons, ceux-ci étant des symboles de base pouvant être décrits par leur colinéarité, leur terminaison (points de fond d'un segment), etc. Dans la figure 1.2(a), le nombre de terminaisons entre les deux régions est identique alors que dans la figure 1.2(b), il y a trois terminaisons pour la région supérieure et quatre pour la région inférieure, ce qui expliquerait pourquoi elles sont plus facilement discernables. Récemment, [Tyler, 2004] suggère que les statistiques globales ne devraient pas être le seul domaine de recherche dans la perception des textures. En effet, il attache plus d'importance aux mécanismes utilisés par les humains pour comparer différents exemples de textures. Concernant le processus de visualisation, des recherches ont été menées sur l'étude des cerveaux de macaques qui réagissent de façon similaire à celle des cerveaux humains. [Valois *et al.*, 1982] enregistrent la réponse des cellules du cortex visuel du macaque à un signal sinusoïdal selon plusieurs fréquences et orientations et en concluent que ces cellules sont réglées pour de petites variations de fréquences et d'orientations. Ces recherches ont motivé l'utilisation de filtres comme par exemple les filtres de Gabor [Turner, 1986, Jain et Farrokhnia, 1990, Higgins et Wakeley, 1994, Shen et Bai, 2008] qui permettent une bonne approximation des caractéristiques de cellules dans le cortex visuel de certains mammifères.




FIG. 1.2 – Images contenant des textures de second ordre statistique identiques

De nombreuses études ont été et sont encore menées pour essayer d'expliquer les capacités du système visuel humain à discerner les textures. La vision humaine offre des performances remarquables même en l'absence d'un contexte favorable. En effet, nous sommes capables d'identifier, de reconnaître une texture ayant subi de fortes distorsions géométriques. Le système visuel interprète la déformation de la texture non comme une perturbation des propriétés géométriques du champ texturé, mais comme une variation de la géométrie qui supporte la texture. Toute la question réside alors dans la possibilité ou non de produire un système informatique ayant une interprétation proche de celle du système visuel humain.

### 1.1.4 Propriétés de perception des textures

Dans [Brady, 2003], l'auteur décrit deux propriétés qui sont essentielles dans la façon de percevoir une texture : la régionalité et la résolution.

La régionalité correspond au voisinage autour d'un pixel/voxel. La figure 1.3 présente plusieurs régionalités d'une même texture avec tout d'abord en (a) une régionalité de 1. Dans cet exemple, nous ne pouvons pas encore parler de textures puisque la région est décrite par un unique pixel. En effet, la notion de textures apparaît dès lors où une région est composée d'un pixel/voxel et d'un voisinage non nul qui lui est associée. La figure 1.3(b) présente un exemple de régionalité égale à  $3^2$ . Si nous la comparons avec la figure 1.3(c) (régionalité égal à  $9^2$ ), celle-ci ne contient qu'une partie des motifs présents dans la texture. L'information que l'on peut obtenir sur une texture dépend donc très fortement de la taille du voisinage que l'on considère. Il est donc difficile de caractériser correctement une texture si la régionalité n'est pas choisie de façon adéquate.

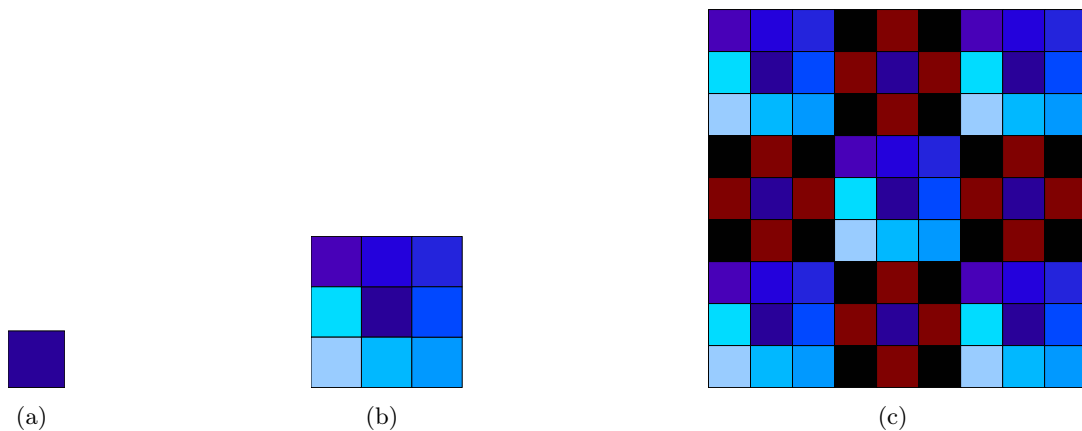


FIG. 1.3 – Information sur une texture selon plusieurs régionalités

La résolution est également primordiale en analyse de textures dans le sens où une texture peut apparaître comme différente selon le niveau de précision auquel celle-ci est observée. A forte résolution, nous caractérisons ce qui constitue les primitives de bases d'une texture (perle, granulé de sable, ...). A faible résolution, la texture peut apparaître comme une juxtaposition des motifs de base plus grossiers. Selon l'échelle d'observation, on aura des caractéristiques différentes mais complémentaires. Ce principe est notamment

utilisé par les ondelettes ou les fractales multirésolutions. La figure 1.4 illustre bien ce phénomène. En nous éloignant, l'information concernant la texture aux résolutions hautes est perdue au profit des informations textures basses résolutions.




FIG. 1.4 – Représentation d'une texture selon plusieurs résolutions

Nous pouvons conclure qu'une bonne méthode d'analyse de textures doit être capable de donner des informations sur une texture à plusieurs niveaux de précision. Dans [Unser, 1995], l'auteur affirme qu'une méthode d'analyse multi-niveaux est plus performante qu'une méthode d'analyse limitée à une seule résolution. Les techniques de multirésolution permettent donc d'extraire des caractéristiques à des échelles variées mais nous verrons aussi que leur utilisation peut se justifier pour d'autres raisons. Par exemple, elles peuvent être utilisées pour réduire la complexité des traitements, en analysant une image à une résolution plus faible ou bien pour initialiser une segmentation [Jung, 2006, Aldasoro et Bhalerao, 2007]. Parmi les méthodes utilisant les propriétés de multirésolution, nous retrouvons les méthodes d'analyse fréquentielle avec notamment les filtres de gabor ou ondelettes [Knutsson et Granlund, 1983, Jain et Farrokhnia, 1990, Mallat, 1989], mais aussi les méthodes pyramidales [Samet, 1984, Spann et Wilson, 1985, Wilson et Spann, 1988].

## 1.2 Méthodes d'extraction de caractéristiques de textures

Dans [Tuceryan et Jain, 1998], les auteurs présentent un état de l'art sur les méthodes d'analyse de textures 2D à l'intérieur duquel ils proposent une classification de ces techniques selon quatre familles principales :

- les méthodes statistiques
- les méthodes géométriques
- les méthodes basées sur un modèle
- les méthodes empruntées au traitement du signal

Afin d'introduire dès à présent la philosophie des méthodes que nous présentons dans la suite, nous avons choisi de produire une classification différente des méthodes existantes. Nous présentons dans un premier temps les méthodes proposant une analyse basée sur

l'extraction des motifs d'une texture. Les méthodes basées sur une analyse fréquentielle regroupant principalement la transformée de Fourier, les filtres de Gabor et la transformée en ondelette sont ensuite présentées. Celles-ci permettent notamment de mettre en évidence l'importance de la multirésolution. Dans une troisième sous-section, nous abordons les méthodes basées sur un modèle, qui permettent l'introduction de connaissances *a priori*. Une quatrième partie nous permet de présenter des méthodes qui proposent une analyse spatiale de l'intensité des niveaux de gris. Enfin, nous passons en revue les propositions de certains auteurs qui tentent de déployer des méthodes calquées sur le système visuel humain afin de décrire les textures de manière plus efficace.

## 1.2.1 Les méthodes basées sur une analyse des motifs

### 1.2.1.1 Le spectre de textures

Le spectre de textures est une approche présentée dans [Wang et He, 1990]. Cette méthode propose de décomposer une image en un ensemble d'unités appelées "unités de textures". Chacune d'elles se compose de  $n$  éléments ayant pour valeur 0, 1 ou 2. Pour un voisinage de pixels  $3 \times 3$  (8 voisins), il est possible d'obtenir jusqu'à  $3^8$  soit 6561 unités de textures différentes.

Étant donné une matrice de pixels de taille  $3 \times 3$ , cette méthode considère un ensemble d'éléments  $V = V_0, V_1, \dots, V_8$  avec  $V_0$  l'intensité du pixel central et  $V_1, \dots, V_8$  l'intensité des pixels voisins. Les unités de textures correspondantes sont représentées par l'ensemble  $TU = E_1, E_2, \dots, E_8$ .

$$E_i = \begin{cases} 0 & \text{si } V_i < V_0 \\ 1 & \text{si } V_i = V_0 \\ 2 & \text{si } V_i > V_0 \end{cases} \quad (1.1)$$

avec  $i = 1, 2, \dots, 8$

A cette unité de textures est alors associé un label calculé à partir de la formule suivante :

$$N_{TU} = \sum_{i=1}^8 E_i 3^{i-1}$$

avec  $N_{TU}$  le label de l'unité de textures et  $E_i$  l'élément  $i$  de l'unité de textures.

A partir du spectre de textures, [He et Wang, 1991] proposent de calculer un certain nombre de caractéristiques comme la symétrie noir et blanc, la symétrie géométrique, le degré de direction, l'orientation, la symétrie centrale. Les formules permettant d'obtenir ces valeurs sont les suivantes :

#### Symétrie noir et blanc

$$BWS = \left[ 1 - \frac{\sum_{i=0}^{3279} |S(i) - S(6560 - i)|}{\sum_{i=0}^{6560} S(i)} \right] * 100 \quad (1.2)$$

où  $S(i)$  est la fréquence d'apparition de l'unité de textures  $i$  dans le spectre de textures.

### Symétrie géométrique

$$GS = [1 - \frac{1}{4} * \sum_{j=1}^4 \frac{\sum_{i=0}^{6560} |S_j(i) - S_{j+3}(i)|}{2 * \sum_{i=0}^{6560} S_j(i)}] * 100 \quad (1.3)$$

où  $S_j(i)$  est la fréquence d'apparition de l'unité de textures  $i$  dans le spectre de textures prenant en compte l'ordre de direction  $j$ .

Illustration de l'ordre de direction :

$E_1$	$E_2$	$E_3$	.....	$E_6$	$E_7$	$E_8$
$E_8$		$E_4$		$E_5$		$E_1$
$E_7$	$E_6$	$E_5$		$E_4$	$E_3$	$E_2$
Ordre 1.				Ordre 4.		

### Degré de direction

$$DD = [1 - \frac{1}{6} * \sum_{m=1}^3 \sum_{n=m+1}^4 \frac{\sum_{i=0}^{6560} |S_m(i) - S_n(i)|}{2 * \sum_{i=0}^{6560} S_m(i)}] * 100 \quad (1.4)$$

où  $m$  et  $n$  représentent un ordre de direction.

### Caractérisation de l'orientation

#### 1. Micro - structure horizontale

$$MHS = \sum_{i=0}^{6560} S(i) * HM(i) \quad (1.5)$$

où  $HM(i) = P(a, b, c) * P(e, f, g)$ , la mesure horizontale de l'unité de textures  $i$ .

#### 2. Micro - structure verticale

$$MVS = \sum_{i=0}^{6560} S(i) * VM(i) \quad (1.6)$$

où  $VM(i) = P(a, h, g) * P(c, d, e)$ , la mesure verticale de l'unité de textures  $i$ .

#### 3. Micro - 1<sup>ère</sup> diagonale de la structure

$$MDS1 = \sum_{i=0}^{6560} S(i) * DM1(i) \quad (1.7)$$

où  $DM1(i) = P(h, a, b) * P(d, e, f)$ , la mesure de la première diagonale de l'unité de textures  $i$ .

4. Micro - 2<sup>nde</sup> diagonale de la structure

$$MDS2 = \sum_{i=0}^{6560} S(i) * DM2(i) \quad (1.8)$$

où  $DM1(i) = P(b, c, d) * P(f, g, h)$ , la mesure de la seconde diagonale de l'unité de textures  $i$ .

où  $P(a, b, c), P(e, f, g), P(a, h, g), P(c, d, e), P(h, a, b), P(d, e, f), P(b, c, d)$  et  $P(f, g, h)$  est le nombre d'éléments ayant la même valeur parmi  $E_a, E_b, E_c$ , etc. Ci-dessous, une illustration de cette correspondance :

$E_a$	$E_b$	$E_c$
$E_h$		$E_d$
$E_g$	$E_f$	$E_e$

### Symétrie centrale

$$CS = \sum_{i=0}^{6560} S(i) * K(i)^2 \quad (1.9)$$

où  $K(i)$  est le nombre de paires possédant la même valeur entre les éléments  $(E_a, E_e), (E_b, E_f), (E_c, E_g)$  et  $(E_d, E_h)$ .

Afin d'analyser la répartition des motifs, [Al-Janobi, 2001] propose une nouvelle méthode d'analyse de textures, appelée *Cross diagonal texture Matrix (CDTM)*, utilisant les propriétés de la GLCM et des spectres de textures. Les huit éléments de l'unité de textures obtenus à partir d'un voisinage de  $3 \times 3$  pixels sont divisés en deux groupes contenant chacun quatre éléments comme illustré par la figure 1.5. Ces deux groupes sont deux unités de textures appelées "unité de textures en croix"(CTU) et "unité de textures en diagonale" (DTU). Comme dans la méthode du spectre de textures chacun des éléments des deux groupes se voit affecter une des trois valeurs 0, 1, ou 2. Il est alors possible de calculer un label de textures pour chacune des unités de textures CTU et DTU. Voici comment les calculer :

$$N_{CTU} = \sum_{i=1}^4 E_{Ci} \cdot 3^{i-1} \quad (1.10)$$

$$N_{DTU} = \sum_{i=1}^4 E_{Di} \cdot 3^{i-1} \quad (1.11)$$

où  $N_{CTU}$  est le label de l'unité de textures CTU,  $N_{DTU}$  est le label de l'unité de textures DTU,  $E_{Ci}$  est le  $i^{eme}$  élément appartenant à l'unité de textures CTU,  $E_{Di}$  est le  $i^{eme}$  élément de l'unité de textures DTU.

Une matrice de cooccurrence est alors construite à partir des paires de label ( $N_{CTU}, N_{DTU}$ ). Afin de caractériser une texture, des caractéristiques sont calculées sur cette matrice tout comme dans la méthode des matrices de cooccurrence des niveaux de gris d'Haralick (voir section 1.2.4.3).

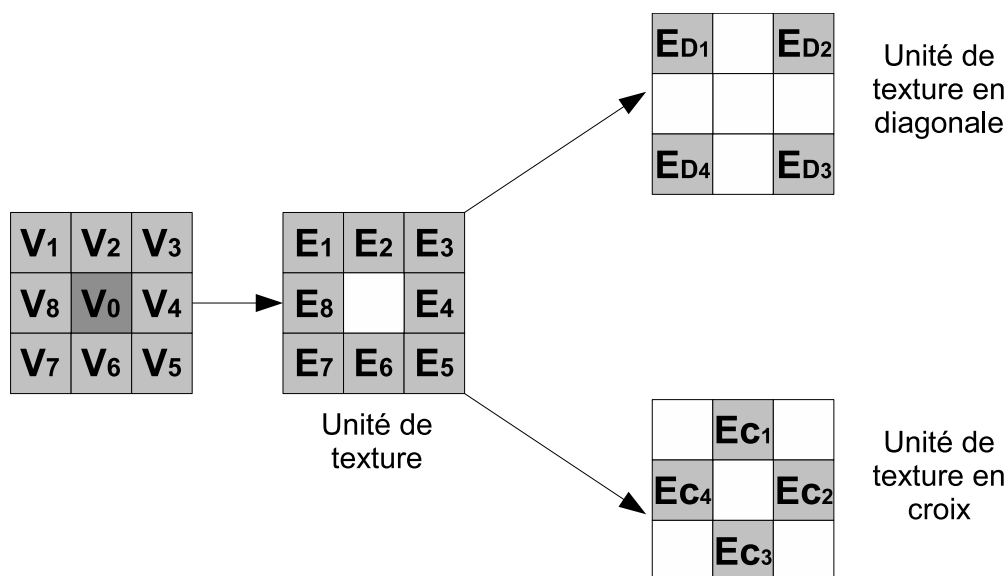


FIG. 1.5 – Construction des unités de textures en croix et en diagonale avec un voisinage de  $3^2$  pixels.

### 1.2.1.2 Méthode des motifs binaires (LBP)

Cette méthode, introduite par [Ojala *et al.*, 1996] est fortement inspirée par la méthode précédente. L'un des intérêts de cette méthode est de pouvoir générer un nombre d'unités de textures plus restreint. Pour un voisinage de 8 pixels, il est possible d'obtenir  $2^8 = 256$  unités de textures différentes contre 6561 pour la méthode du spectre de textures. Cette méthode est utilisée avec succès dans divers domaines comme la détection ou la reconnaissance faciale [Ahoen *et al.*, 2006, Zhao et Pietikäinen, 2007]. En terme d'efficacité discriminante, cette méthode offre de bonnes performances et contient des informations structurelles et statistiques. L'opérateur LBP (local binary pattern) peut être invariant aux rotations et changements d'échelles et offre une grande tolérance face aux changements de luminosité. De plus, c'est une méthode de faible complexité qui rend possible l'analyse d'images 2D en temps réel.

L'opérateur LBP propose d'assigner un code binaire à un pixel en fonction de son voisinage. La valeur d'intensité d'un pixel central est utilisée pour seuiller ses pixels voisins afin de générer un motif binaire (Figure 1.6). Les pixels de ce motif binaire sont alors multipliés par des poids et sommés afin d'obtenir un code LBP.

Dans [Ojala *et al.*, 2001, Ojala et Pietikäinen, 2002] des extensions de cette méthode sont proposées. Celles-ci permettent :

- un choix sur le voisinage afin de calculer un code LBP






FIG. 1.6 – Construction d'un motif binaire et calcul du code LBP

– une invariance à la rotation

Un voisinage pour un pixel central est réparti sur un cercle et construit à partir de deux paramètres : le nombre de voisins sur le cercle et un rayon pour définir une distance entre un pixel central et ses voisins. Définissons une texture :  $T = t(g_c, g_0, \dots, g_{P-1})$ ,  $g_c$  correspond à la valeur de niveau de gris du pixel central et  $g_p$ , avec  $p = 0, \dots, P-1$ , correspond au niveau de gris de  $P$  pixels espacés régulièrement sur un cercle de rayon  $R$ . Si les coordonnées de  $g_c$  sont égales à  $(0, 0)$ , alors les coordonnées de  $g_p$  sont données par  $(-R \sin(2\pi p/P), -R \cos(2\pi p/P))$ . Comme nous pouvons le voir à la figure 1.7, les coordonnées d'un voisin ne sont pas forcément situées au centre d'un pixel. Dans ce cas, le niveau de gris est calculé par l'intermédiaire d'une interpolation. Voici une représentation graphique de  $T$  faisant varier les paramètres  $P$  et  $R$  :




FIG. 1.7 – Représentation du pixel central  $g_c$  et de son voisinage  $g_p$

Comme dans la méthode LBP classique, le pixel central n'est pas utilisé pour la caractérisation des textures. En effet, indépendamment du voisinage  $g_p$ , ce pixel décrit uniquement une intensité lumineuse ce qui n'est pas forcément utile [Ojala et Pietikäinen, 2002].

$T$  peut alors s'écrire  $T = t(g_0, \dots, g_{P-1})$ . Par la suite,  $g_c$  est utilisé comme un seuil de la façon suivante :

$$T = t(s(g_0 - g_c), \dots, s(g_{P-1} - g_c))$$

avec  $s(x)$  égal à 1 si  $x$  positif et  $s(x)$  égal à 0 si  $x$  est strictement négatif.


En multipliant chaque fonction  $s(g_p - g_c)$  par un poids de valeur  $2^p$ , on obtient alors un code binaire tel que :

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c)2^p \quad (1.12)$$


Pour supprimer l'effet de rotation, un code LBP ( $LBP_{P,R}^{ri}$ ) est défini en vue de retourner une valeur unique quelle que soit la rotation appliquée :

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i)\} \quad (1.13)$$

avec  $i = 0, 1, \dots, P - 1$ , et  $ROR(x, i)$  permettant de faire une rotation bit à bit de  $x$  et  $i$  fois. Avec cette méthode, 36 motifs différents sont considérés au lieu de  $2^P$ .



Motifs uniformes



Motifs non-uniformes

FIG. 1.8 – Exemples de motifs uniformes et non-uniformes

Pour une valeur  $R = 1$ ,  $LBP_{P,R}^{ri}$  est l'équivalent de  $LBPROT$  dans [Pietikäinen *et al.*, 2000]. Dans cet article, il est montré que  $LBPROT$  ne permet pas d'obtenir de bonnes performances. La principale raison est que l'occurrence des fréquences de certains des 36 motifs possibles varie fortement (instabilité). Pour résoudre ce problème, une mesure est effectuée sur les motifs afin de déterminer s'ils sont uniformes. Pour cela une fonction  $U$  retourne le nombre de transitions spatiales (passage de 0 à 1 ou de 1 à 0). Si le nombre de transitions est supérieur à deux, alors le motif est considéré comme

non-uniforme. L'opérateur appelé  $LBP_{P,R}^{riu2}$  est défini de la façon suivante :

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{si } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{sinon} \end{cases} \quad (1.14)$$

avec  $U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|$  une mesure d'uniformité.

Concernant les motifs uniformes, l'opérateur  $LBP^{riu2}$  correspond à la somme des bits du voisinage. Au contraire si les motifs sont non-uniformes, l'opérateur est affecté à la valeur  $P + 1$  (Figure 1.8). Le nombre d'apparitions de chaque code est accumulé dans un histogramme de taille  $P + 2$ . Chaque tranche de cet histogramme donne une estimation de la probabilité d'apparition d'un motif dans une texture. Les textures sont caractérisées en utilisant directement l'histogramme des codes binaires.

Dans [Guo *et al.*, 2009], les auteurs proposent une variation de cette méthode en coordonnant une invariance à la rotation à la fois globale et locale. Dans un premier temps, ils utilisent la distribution LBP pour déterminer l'orientation principale d'une texture et l'utilisent afin d'aligner l'histogramme LBP. Dans la figure 1.8, le motif uniforme obtient le même code LBP quelle que soit son orientation. Le fait d'aligner l'histogramme LBP selon l'orientation principale (information globale) permet de différencier ces 3 motifs uniformes en leur affectant des codes binaires différents. Enfin, les auteurs proposent également un nouveau descripteur de textures LBP *variance* (LBPV) permettant de mesurer les informations locales de contraste.

### 1.2.1.3 La loi de Zipf

La loi de Zipf, également connue comme loi de puissance, a été déterminée de façon empirique par Zipf. Cette technique fonctionne de façon très similaire à la méthode LBP en proposant des mesures construites à partir de la fréquence d'apparition de motifs présents dans une texture. Dans [Caron *et al.*, 2007], les auteurs donnent une explication sur son utilisation à la fois en image et dans d'autres domaines d'application. A la base, cette méthode est utilisée pour l'étude de textes. En effet, selon la loi de Zipf, la fréquence d'occurrence de motifs dans un texte suit une loi de puissance. Si nous définissons un ensemble de motifs  $P_1, P_2, \dots, P_R$  et leurs fréquences d'apparition correspondantes  $N_1, N_2, \dots, N_R$  alors la fréquence d'apparition  $N_{\sigma(i)}$  du motif  $P_{\sigma(i)}$  de rang  $i$  est donnée par :

$$N_{\sigma(i)} = ki^{-\alpha} \quad (1.15)$$

avec  $k$  et  $\alpha$  deux constantes.

Durant ses travaux sur les textes naturels, [Zipf, 1935] a découvert un autre modèle de la loi puissance appelé loi de Zipf inverse. Selon cette loi, le nombre  $I$  de mots distincts avec une fréquence d'apparition  $f$  est donné par :

$$I(f) = af^{-b} \quad (1.16)$$

avec  $a$  et  $b$  deux constantes.

La loi de Zipf et la loi de Zipf inverse sont toutes les deux applicables à l'analyse d'image

[Caron *et al.*, 2007]. En analyse d'image 2D, les mots sont considérés comme des blocs adjacents de pixels de taille  $3^2$ . A l'intérieur des images, les niveaux de gris ne sont pas utilisés directement. Sans une étape de quantification, le nombre de motifs possibles serait bien trop important pour avoir une répartition statistique significative des fréquences (figure 1.9). Dans [Caron *et al.*, 2007], les auteurs proposent de requantifier l'image de la façon suivante :

$$c(x, y) = \text{int}\left[\frac{Ng(x, y)}{255}\right] \quad (1.17)$$

avec  $N$  le nombre de classes,  $g(x, y)$  l'intensité aux coordonnées  $(x, y)$  et  $c(x, y)$  la nouvelle valeur de niveaux de gris.

2	2	40
2	1	216
210	255	34

0	0	1
0	0	7
7	8	1

FIG. 1.9 – A gauche le motif original et à droite le motif requantifié avec  $N = 9$ .

De cette façon, les motifs d'une image sont répertoriés par un parcours effectué à l'aide d'un masque ( $3^2$  dans [Caron *et al.*, 2007]). Il est alors possible de compter la fréquence d'apparition des motifs (loi de Zipf) ou le nombre de motifs avec une fréquence  $f$  (loi de Zipf inverse). Ces deux lois sont généralement représentées à l'aide d'un graphique bi-logarithmique. L'aire ou la pente de la courbe obtenue sont deux caractéristiques qu'il est possible d'utiliser pour identifier une texture ou pour la détection d'objets dans une image [Caron *et al.*, 2007].

#### 1.2.1.4 Polygones de Voronoï

Dans [Tuceryan et Jain, 1990], les auteurs proposent d'utiliser les polygones de Voronoï pour segmenter les textures. Dans cette approche, ils cherchent à caractériser les textures à travers la distribution spatiale locale des germes qui constituent les différents polygones de Voronoï.

Si nous considérons un espace euclidien  $E$  avec  $S$  un ensemble fini de  $n$  points (germes) de  $E$ , alors nous appelons région de Voronoï ou cellule de Voronoï associée à un élément  $p$  de  $S$ , l'ensemble des points qui sont plus proches de  $p$  que de tout autre point de  $S$ .

$$Vor_s(p) = \{x \in E / \forall q \in S, d(x, p) \leq d(x, q)\} \quad (1.18)$$

Pour un ensemble de germes, le diagramme de Voronoï se construit en déterminant les médiatrices de chaque couple de germes. Un point d'une médiatrice appartient alors à une frontière de Voronoï s'il est équidistant d'au moins deux germes et s'il n'existe pas de distance plus faible entre ce point et un autre germe de l'ensemble.

Pour appliquer le maillage de Voronoï à une image en niveaux de gris, il faut pouvoir extraire des germes de cette image. [Tuceryan et Jain, 1990] proposent l'algorithme simple suivant :

1. Convoluer l'image avec le laplacien d'une gaussienne (LoG).
2. Sélectionner les maximums locaux dans l'image filtrée. Un pixel sera sélectionné parmi les maximums locaux si sa valeur est supérieure à six ou plus de ses huit voisins. L'image est ensuite binarisée pour ne conserver que ces mêmes maximums locaux.
3. Réaliser le diagramme de Voronoï en analysant les composantes connexes sur l'image binarisée. Chaque composante connexe est définie comme étant un germe pour le diagramme de Voronoï.

Par la suite, des caractéristiques sont calculées pour chaque cellule de Voronoï. Les germes possédant des caractéristiques identiques sont regroupés pour construire des régions de textures uniformes. Les moments de la surface des polygones de Voronoï sont des caractéristiques intéressantes permettant de refléter la distribution spatiale et les formes de germes dans une image texturée. Le  $(p + q)^{eme}$  ordre des moments de la surface d'une région  $R$  centrée sur un germe de coordonnées  $(x_0, y_0)$  est défini de la façon suivante :

$$m_{pq} = \int_R \int (x - x_0)^p (y - y_0)^q dx dy \quad (1.19)$$

A partir des moments, il est proposé dans [Tuceryan et Jain, 1990] de calculer les caractéristiques de textures spécifiées dans le tableau 1.1.

Caractéristiques	Méthodes de calcul
$f_1$	$m_{00}$
$f_2$	$\sqrt{\bar{x}^2 + \bar{y}^2}$
$f_3$	$\tan^{-1}(\bar{y}/\bar{x})$
$f_4$	$\left[ \frac{[(m_{20} - m_{02})^2 + 4m_{11}^2]^{0.5}}{[(m_{20} - m_{02})^2 + 4m_{11}^2]^{0.5} + m_{20} + m_{02}} \right]^{0.5}$
$f_5$	$\tan^{-1}(2m_{11}/(m_{20} - m_{02}))$

TAB. 1.1 – Tableau des caractéristiques calculées sur les polygones de Voronoï

Dans [Tuceryan et Jain, 1990], les polygones de Voronoï sont utilisés dans une problématique de segmentation de textures. Les régions ayant des propriétés de textures homogènes sont fusionnées pour produire une segmentation. Il serait intéressant d'évaluer cette méthode dans le cadre d'une classification en calculant des caractéristiques capables de décrire une texture dans sa globalité et non localement.

### 1.2.1.5 Extraction de textures par l'analyse de composantes connexes

La notion de composantes connexes est très utilisée dans l'analyse d'images binaires et dans l'analyse de documents. Elle est également répandue dans le domaine des textures et permet d'analyser les structures ainsi que les motifs binaires composant une texture. Dans [Mital *et al.*, 1994, Goyal *et al.*, 1994a, Goyal *et al.*, 1994b, Goyal *et al.*, 1995], les auteurs

proposent de caractériser de façon structurelle les textures. Pour cela, ils utilisent notamment la caractéristique de compacité d'un motif qui est calculée en 2D en faisant le quotient de son périmètre sur son aire. De nouvelles méthodes pour calculer le périmètre d'une composante connexe sont également proposées afin d'obtenir une caractéristique de compacité plus stable et de meilleure qualité. Cette caractéristique est invariante à tout type de transformation comme la translation, la rotation et les changements d'échelle [Zhang et Tan, 2002].

Récemment, une méthode de classification de textures utilisant la notion de composantes connexes a été proposée dans [Shoshany, 2008]. Une texture en niveaux de gris est décomposée en une succession de textures binaires 2D ce qui permet une étude des motifs (Figure 1.10). Dans cette approche, l'ensemble des images binaires est construit en utilisant des binarisations globales effectuées avec différentes valeurs de seuil.  $k$  images binaires sont ainsi calculées en faisant varier le seuil de binarisation, avec  $k \in \{1, 256\}$ . Pour classifier les textures, Shoshany propose ensuite d'utiliser les trois caractéristiques suivantes, dont la complémentarité a été prouvée dans [Luo et Savakis, 2001] :

le nombre de composantes connexes,

l'hétérogénéité des motifs,

$$SW = - \sum S_i \ln S_i \quad (1.20)$$

avec  $S_i$  l'aire relative d'une composante connexe  $i$ ,

la dominance,

$$ED = \sum (S_i)^2 \quad (1.21)$$




FIG. 1.10 – Représentation d'une suite de textures binaires 2D construite à partir de seuils de binarisation évoluant de façon croissante.

L'hétérogénéité des motifs représente leur niveau de fragmentation, et la dominance le nombre de motifs larges dans une distribution. Ces caractéristiques sont calculées sur l'ensemble des composantes des textures binaires, c'est à dire à la fois sur les motifs blancs (*foreground*) et les motifs noirs (*background*). A partir de ces attributs de textures, une technique de *clustering* hiérarchique [Borgatti, 1994] est utilisée pour analyser les dissimilarités entre les différents types de textures. D'un point de vue résultat, cette approche permet d'obtenir de bonnes performances en classification sur des images texturées et il pourrait être intéressant de l'adapter afin de pouvoir l'utiliser dans des problématiques de segmentation de textures.

### 1.2.1.6 Autres méthodes

De nombreuses autres méthodes permettent de caractériser une texture par l'analyse de ses structures et de ses primitives de base. Dans [Zucker, 1976], il est proposé un modèle permettant à partir d'une texture idéale, composée de primitives régulières, de synthétiser une texture observable. Cette texture idéale est considérée comme un maillage représenté par un graphe isomorphe. Pour générer la texture observée, des transformations déterministes ou stochastiques sont appliquées sur ce graphe. Il est alors possible de mesurer la compatibilité entre la texture idéale et la texture observée. [Fu, 1982] décrit la texture à l'aide d'une grammaire d'arbre. Dans cette approche, l'image est divisée en fenêtres/primitives qui peuvent à leur tour être divisées jusqu'à obtenir un élément de base. Ces primitives définissent une grammaire à laquelle sont associées une ou plusieurs règles de placement. De cette façon, une texture est vue comme une phrase dans le langage défini par la grammaire considérée. Cette méthode est adaptée à l'analyse mais également à la synthèse de textures. Dans [Voorhees et Poggio, 1987], les auteurs affirment que les taches jouent un rôle important dans la perception de la texture. Pour extraire les taches de l'image, ils utilisent le filtre *Laplacian of Gaussian* (LoG) à plusieurs échelles. [Varma et Zisserman, 2004] proposent de déterminer des textons à partir d'un banc de filtres. Ce banc de filtres est construit en utilisant des filtres gaussien et LoG selon plusieurs orientations et échelles. Les réponses de filtres par classe de textures sont regroupées et classifiées par l'algorithme des *K-Means*. Les centroïdes de chaque classe ainsi trouvés sont considérés comme des textons. Une texture contient  $K$  textons et peut être caractérisée par la proportion des pixels labellisés comme un texton particulier.

### 1.2.1.7 Bilan

L'objectif de ce type de méthodes est d'identifier les structures de base qui se répètent périodiquement pour constituer une texture. Le principe le plus courant est ensuite de comptabiliser le nombre d'occurrences de chacun de ces motifs ou de les regrouper en régions pour classifier ou segmenter les textures. Le problème réside alors dans la sélection des motifs pertinents permettant d'obtenir une caractérisation robuste. Ce type de méthode paraît bien adapté au traitement de textures déterministes et observables constituées de motifs répétitifs. Le problème est de pouvoir gérer la variabilité que peut subir chaque motif. Nous avons aussi mentionné la difficulté d'utiliser les bonnes régionalité et résolution d'observation qui permettent d'identifier correctement les motifs. Notons enfin que ce type de méthode peut fournir une description des textures facilement appréhendable par un humain, nous le retenons donc comme pertinent vis à vis de nos objectifs.

## 1.2.2 Les méthodes fréquentielles

Ces méthodes, souvent utilisées en traitement du signal, permettent d'analyser une texture en identifiant les différentes fréquences qui la composent. Parmi elles, on retrouve notamment la transformée de Fourier, les filtres de Gabor ainsi que les ondelettes. De façon générale, la transformation linéaire d'une image  $f$  est obtenue en calculant la

corrélation de  $f$  et d'une fonction  $\psi_\lambda$  :

$$\int_{-\infty}^{+\infty} f(x, y) \bar{\psi}_\lambda(x, y) dx dy \quad (1.22)$$

avec  $\lambda$  un ensemble de paramètres propre à  $\psi$  et  $\bar{(\ )}$  le complexe conjugué de la quantité en argument.

### 1.2.2.1 La transformée de Fourier

La transformée de Fourier [Bracewell, 1986] est une des méthodes utilisées pour l'analyse linéaire d'une image. La fonction  $\psi$  utilisée pour obtenir la transformée linéaire d'une image prend comme valeur :

$$\psi_\lambda(x, y) = e^{i2\pi(ux+vy)} \quad (1.23)$$

avec  $\lambda = (u, v)$  les fréquences à étudier. A partir de la transformée de Fourier, il est possible de calculer le spectre de puissance qui est défini comme le carré du module de la transformée de Fourier :

$$P(u, v) = F_R(u, v)^2 + F_I(u, v)^2 \quad (1.24)$$

avec  $F_R(u, v)$  et  $F_I(u, v)$  la partie réelle et la partie imaginaire de la transformée de Fourier. A partir du spectre de puissance, il est possible de calculer plusieurs caractéristiques pour décrire une image. Dans [Petrou et Sevilla, 2006], les auteurs donnent une explication sur la mesure de la périodicité d'une texture à partir du spectre de puissance. En considérant les opérateurs  $P_u(u) = \sum_v P(u, v)$  et  $P_v(v) = \sum_u P(u, v)$ , l'observation répétitive de pics démontre une certaine périodicité dans l'image. En utilisant le spectre de puissance, il est également possible de calculer la dimension fractale d'une image. Pour cela, il suffit de tracer une courbe des intensités selon une ligne du spectre de puissance. Formellement, une ligne  $L$  d'un spectre de puissance de taille  $(M, N)$  sera égale à  $P(u, v)$  avec  $u = a \cos \theta$ ,  $v = a \sin \theta$  et  $a = \{1, 2, 3, \dots, \min(M, N)\}$ . La dimension fractale est calculée à partir de la pente de la courbe.

La transformée de Fourier est un outil bien adapté à l'analyse des comportements harmoniques, cependant elle n'est pas appropriée à l'analyse de formes localisées spatialement. Si l'on veut conserver une analyse spectrale tout en ayant une localisation spatiale, il faut adopter une approche espace-fréquence en choisissant des fonctions  $\psi_\lambda$  qui soient à la fois oscillantes et de supports limités. On dit alors que les fonctions  $\psi_\lambda$  constituent des atomes espaces-fréquences.

### 1.2.2.2 Transformée de Fourier fenêtrée et fonction de Gabor

Motivé par la mécanique quantique, Gabor définit en 1946 [Gabor, 1946] les atomes temps-fréquence (espace-fréquence en dimension supérieure) comme des ondes ayant une propagation minimale dans l'espace temps-fréquence. Pour mesurer le contenu de l'information temps-fréquence, il propose de décomposer un signal à partir d'ondes atomiques



## 1.2. MÉTHODES D'EXTRACTION DE CARACTÉRISTIQUES DE TEXTURES

élémentaires. Pour cela la transformée de Fourier est légèrement modifiée par l'introduction d'une fenêtre  $g$ .

$$\psi_\lambda(x, y) = g(x - x_0, y - y_0) \exp(i(2\pi(u_0x + v_0y) + P)) \quad (1.25)$$

avec  $\lambda = (x_0, y_0, u_0, v_0)$ ,  $(u_0, v_0)$  définissant la fréquence spatiale de la sinusoïde, et  $P$  sa phase.

Si l'on exprime la fréquence spatiale à partir d'une coordonnée polaire selon une amplitude  $F_0$  et une direction  $\omega_0$ , on obtient :

$$u_0 = F_0 \cos \omega_0 \quad v_0 = F_0 \sin \omega_0 \quad (1.26)$$

L'énergie de  $\psi_\lambda$  est concentrée autour de  $(x_0, y_0)$  sur un espace de taille  $(\sigma_x, \sigma_y)$ .

La transformée de Fourier de la fonction  $\psi_\lambda$  est :

$$\Psi_\lambda(v_x, v_y) = \hat{g}(v_x - u_0, v_y - v_0) \exp(-i2\pi(x_0(v_x - u_x) + y_0(v_y - u_y) + P)) \quad (1.27)$$

Dans le domaine fréquentiel, l'énergie de  $\Psi_\lambda$  est localisée autour de  $(u_0, v_0)$  dans des intervalles de taille  $(\sigma_{v_x}, \sigma_{v_y})$ .

Lorsque  $g$  prend une forme gaussienne, on dit qu'on effectue une analyse de Gabor.  $g$  représente alors une enveloppe gaussienne qui peut s'écrire :

$$g(x, y) = K \exp(-\pi((\frac{(x - x_0)\cos\theta + (y - y_0)\sin\theta}{\sigma_x})^2 + (\frac{(y - y_0)\cos\theta - (x - x_0)\sin\theta}{\sigma_y})^2))$$

avec  $(x_0, y_0)$  le sommet de la fonction,  $\sigma_x$  et  $\sigma_y$  les écart-types de l'enveloppe gaussienne,  $K$  l'échelle de l'amplitude de l'enveloppe gaussienne,  $\theta$  l'angle de rotation de l'enveloppe gaussienne. La fonction complexe de Gabor s'écrit alors :

$$\psi_\lambda(x, y) = K \exp - \pi((\frac{(x - x_0)\cos\theta + (y - y_0)\sin\theta}{\sigma_x})^2 + (\frac{(y - y_0)\cos\theta - (x - x_0)\sin\theta}{\sigma_y})^2) \cdot \exp(j(2\pi(xF_0\cos\omega_0 + yF_0\sin\omega_0) + P)) \quad (1.28)$$

La figure 1.11 représente le filtre de Gabor dans le domaine fréquentiel mais aussi les différents paramètres agissant sur son orientation et sa forme, et qui mettent en évidence certaines fréquences. Dans la littérature, la sinusoïde complexe et l'enveloppe gaussienne sont souvent orientées dans la même direction avec  $\theta = \omega$ . Il arrive également que les valeurs des écart-types de l'enveloppe gaussienne soient choisies identiques ( $\sigma = \sigma_x = \sigma_y$ ). Enfin, certaines méthodes n'utilisent que la partie réelle qui est considérée comme la partie la plus intéressante et évitent d'utiliser le module qui n'est pas une opération linéaire. L'utilisation de cet outil demande une bonne connaissance du choix des paramètres. Dans un banc de filtres, la fonction de Gabor est utilisée avec plusieurs valeurs d'angles et de fréquences pour balayer au mieux les différentes fréquences présentes dans l'image à analyser. L'angle  $\theta$  prend ses valeurs entre 0 et  $2\pi$  séparées de façon équidistante (souvent tous les 30 ou 45 degrés). L'amplitude  $F_0$  peut s'exprimer en fonction de la longueur d'onde  $f_0$  avec  $F_0 = \frac{1}{f_0}$ . La réponse de la fréquence spatiale de la bande passante  $b$  du filtre de Gabor s'exprime en octave. Elle s'écrit :

$$b = \log_2 \frac{\frac{\sigma}{f_0} \pi + \sqrt{\frac{\ln 2}{2}}}{\frac{\sigma}{f_0} \pi - \sqrt{\frac{\ln 2}{2}}} \quad (1.29)$$

A partir de cette équation, on peut alors exprimer le rapport  $\frac{\sigma}{f_0}$  :

$$\frac{\sigma}{f_0} = \frac{1}{\pi} \sqrt{\frac{\ln 2}{2} \frac{2^b + 1}{2^b - 1}} \quad (1.30)$$

Une valeur de  $b = 1$  octave offre de bonnes performances. On obtient ainsi la relation  $\sigma = 0.56f_0$ . Dans le cas où  $\sigma_x$  et  $\sigma_y$  sont différents, il est conseillé dans [Xie *et al.*, 2005] la relation  $\sigma_y = 2\sigma_x = 1.12f_0$ .

De par leurs qualités à approximer les caractéristiques de cellules du cortex visuel des mammifères, ces filtres sont très utilisés en analyse d'image et notamment dans la caractérisation et la segmentation des textures [Fogel et Sagi, 1989, Bovik *et al.*, 1990, Farrokhnia et Jain, 1991, Jain et Farrokhnia, 1990, Higgins et Wakeley, 1994].




FIG. 1.11 – Représentation du filtre de Gabor et de ses paramètres dans le domaine fréquentiel

### 1.2.2.3 Les ondelettes

Tout comme les filtres de Gabor, les ondelettes permettent une bonne approximation du système visuel des mammifères. [Mallat, 1989] prétend qu'elles permettent une analyse plus proche du système psycho-visuel par rapport à celle obtenue avec la famille de Gabor. De plus, [Chang et Kuo, 1993] décrit les ondelettes comme plus naturelles et efficaces pour des textures composées majoritairement de fréquences moyennes. Les ondelettes sont donc un outil puissant pour la caractérisation de textures et sont très utilisées dans la littérature [Chang et Kuo, 1993, Laine et Fan, 1993, Unser, 1995,

Laine et Fan, 1996, Liapis *et al.*, 1998, Arivazhagan et Ganesan, 2003, Borah *et al.*, 2007, Kim et Kang, 2007].

La transformée en ondelette remplace les ondes sinusoïdales de la transformée de Fourier par une famille générée par translations et dilatations d'une fenêtre appelée ondelette. La fonction  $\psi_\lambda$  prend comme valeur :

$$\psi_\lambda(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x - x_0}{a}\right) \quad (1.31)$$

avec  $\lambda = (x_0, a)$ ,  $x_0$  étant un coefficient de translation et  $a$  un coefficient de dilatation. L'analyse d'une fonction  $f$  se fait ensuite par dilatation et par translation d'une ondelette mère  $\psi$ . Les coefficients d'ondelette  $C_\lambda$  d'un ensemble de coefficient  $\lambda$  sont obtenus de la façon suivante :

$$C_\lambda(x) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \bar{\psi}\left(\frac{x - x_0}{a}\right) dx \quad (1.32)$$

avec  $a$  le coefficient d'échelle,  $x_0$  le coefficient de translation,  $\psi$  l'ondelette mère et  $(\bar{\cdot})$  le conjugué complexe de la quantité en argument.

[Unser et Blu, 2003] affirme l'existence de fonctions d'ondelettes qui génèrent une base dans  $L_2$ . Une fonction  $f \in L_2$  peut être représentée de façon stable à partir de coefficients de détails  $d_a(x_0)$  et de fonctions de base  $\psi_{a,x_0} = 2^{-\frac{a}{2}}$  :

$$f(x) = \sum_{a \in \mathbb{Z}} \sum_{x_0 \in \mathbb{Z}} d_a(x_0) \psi_{a,x_0} = 2^{-\frac{a}{2}} \quad (1.33)$$

Les coefficients d'ondelette  $d_a(x_0)$  sont obtenus à partir du produit scalaire suivant :

$$d_a(x_0) = \langle f, \bar{\psi}_{a,x_0} \rangle_{L_2} \quad (1.34)$$

où  $\bar{\psi}_{a,x_0}$  est la base biorthogonale de  $\psi_{a,x_0}$  tel que  $\langle \bar{\psi}_{a,x_0}, \psi_{a',x'_0} \rangle = \delta_{a-a'} \cdot \delta_{x_0-x'_0}$ .

Pour construire une ondelette mère, il faut utiliser une fonction  $\phi$  appelée fonction d'échelle [Mallat, 1989]. Une ondelette  $\psi$  est exprimée selon la fonction d'échelle  $\phi$  de la façon suivante :

$$\psi(x) = \sqrt{2} \sum g(x_0) \phi(2x - x_0) \quad (1.35)$$

sachant que

$$g(x_0) = (-1)^{1-x_0} h(1 - x_0) \quad (1.36)$$

avec  $h$  le filtre conjugué miroir de la fonction d'échelle  $\phi$ .

Pour qu'une fonction d'échelle  $\phi$  soit admissible, elle doit vérifier plusieurs contraintes. [Unser et Blu, 2003] propose la définition suivante :

**Definition 1.2.1.**  $\phi$  est une fonction d'échelle admissible de  $L_2$  si et seulement si elle satisfait les trois conditions suivantes :

- Critère de la base de Riesz : il existe deux constantes  $A > 0$  et  $B < +\infty$  telles que

$$A \leq \sum_{n \in \mathbb{Z}} \left| \hat{\phi}(w + 2\pi n) \right|^2 \leq B, \quad \forall w \quad (1.37)$$

– *Raffinabilité*

$$\phi(x) = \sqrt{2} \sum h(x_0)\phi(2x - x_0) \quad (1.38)$$

– *Partition d'unité*

$$\sum_{x_0 \in \mathbb{Z}} \phi(x - x_0) = 1 \quad (1.39)$$

#### 1.2.2.4 Décomposition en ondelette discrète

L'algorithme de Mallat propose de décomposer un signal par une succession de filtres passe haut et filtre passe bas [Mallat, 1989]. La décomposition en ondelette n'est pas faite directement à partir des formes explicites de  $\phi(x)$  et  $\psi(x)$  mais à partir des coefficients  $g(x)$  (filtre passe haut) et  $h(x)$  (filtre passe bas). La figure 1.12 présente la décomposition d'un signal 1D à partir de ces deux filtres. A chaque niveau de décomposition, le signal est sous échantillonné par un facteur de deux. En sortie du filtre passe bas  $g(x)$ , nous obtenons des coefficients d'approximations pour une résolution donnée. Ce sont ces coefficients qui sont utilisés pour une décomposition à un niveau plus grossier. La sortie du filtre passe haut permet d'obtenir les coefficients de détail qui donnent une description des hautes fréquences présentes dans un signal.

Pour traiter des images, le mécanisme de décomposition reste le même. Une première convolution est appliquée dans le sens des lignes puis une deuxième dans le sens des colonnes, avec pour chaque convolution une étape de sous échantillonnage (Figure 1.13). Pour une image 2D, quatre images résultats sont obtenues pour un niveau de décomposition :  $A_1$  correspond aux basses fréquences horizontales et verticales,  $D_1$  aux hautes fréquences verticales et basses fréquences horizontales,  $D_2$  aux basses fréquences verticales et hautes fréquences horizontales,  $D_3$  aux hautes fréquences verticales et horizontales. De cette façon, il est possible d'appliquer une décomposition en ondelette discrète sur un signal à  $n$  dimensions [Mallat, 1989].

#### 1.2.2.5 Les frames d'ondelette

La décomposition en ondelette discrète classique n'est pas invariante à la translation. A chaque niveau de décomposition, il y a une étape de sous-échantillonnage et un déplacement même léger pourrait entraîner une représentation différente. Dans le cas d'une image contenant plusieurs textures, celles-ci peuvent apparaître n'importe où et les caractéristiques obtenues à partir d'une décomposition en ondelette standard peuvent ne pas correspondre avec les caractéristiques associées à ces textures.

Les frames d'ondelette permettent de contourner ce problème en éliminant l'étape de sous-échantillonnage de la décomposition en ondelette classique. Unser est le premier à utiliser cette méthode et les résultats qu'il présente sont meilleurs qu'avec une décomposition en ondelette standard [Unser, 1995]. Il fait également la comparaison avec des méthodes d'analyses de textures classiques comme les matrices de cooccurrences, les champs aléatoires de Markov Gaussien et des transformées linéaires locales, qui s'avèrent être moins performantes. Les frames d'ondelette permettent une description invariante aux translations dans une texture. Cependant, une partie de l'information est dupliquée et les caractéristiques

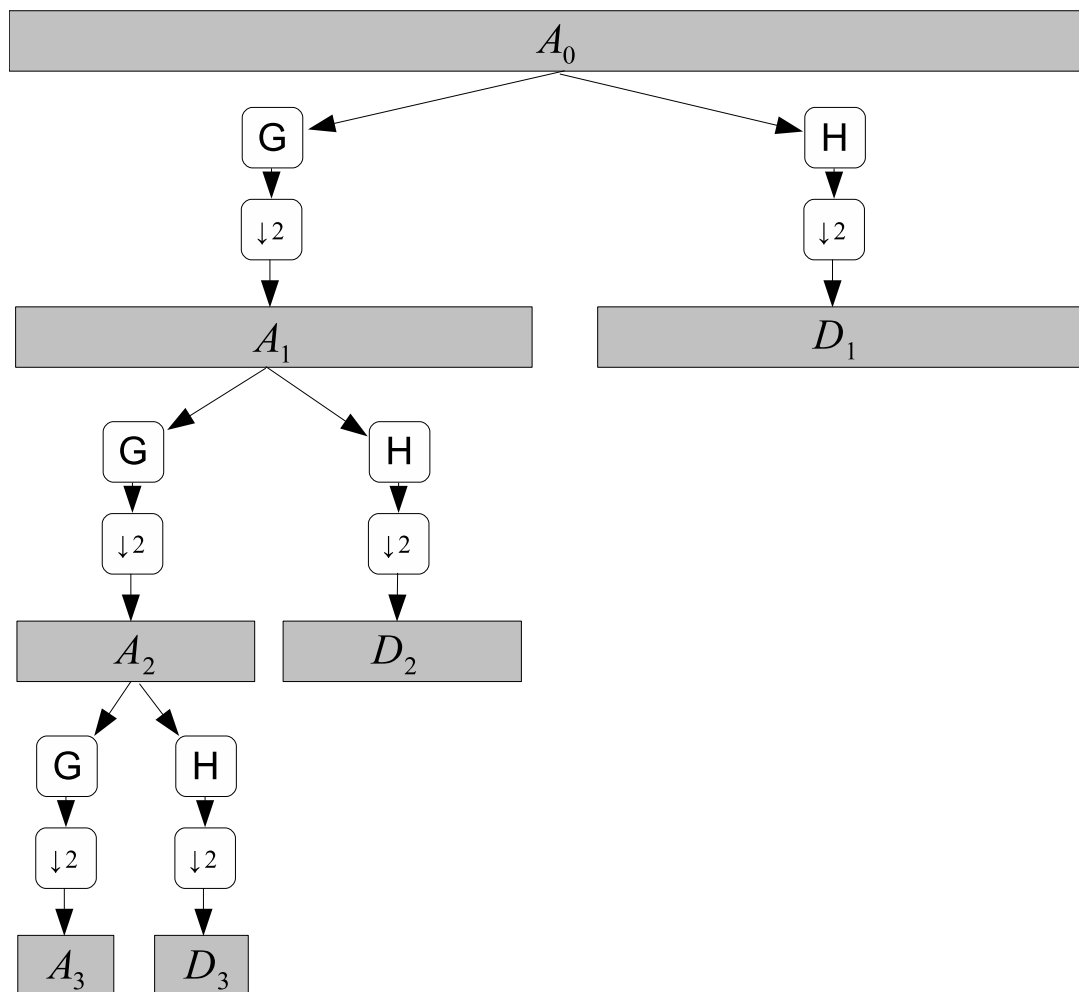


FIG. 1.12 – Décomposition en ondelette d'un signal 1D

obtenues à partir du signal ou de l'image d'origine sont redondantes. Enfin, cette méthode possède une complexité non-négligeable ce qui peut être problématique dans certains cas d'applications.

### 1.2.2.6 Les paquets d'ondelette

Les paquets d'ondelette sont une extension de la décomposition en ondelette standard et permettent une analyse plus précise des fréquences présentes dans une image. En effet, la transformée en ondelette discrète utilise uniquement les coefficients d'approximations pour une éventuelle décomposition à un niveau plus grossier. Dans le cas de la transformée en paquets d'ondelette, le passage à un niveau inférieur se fait en décomposant les coefficients d'approximations ainsi que les coefficients de détails. Cette méthode permet d'avoir à la fois une analyse sur les basses fréquences mais aussi sur les hautes fréquences. Enfin, de par le sous-échantillonnage, le nombre de coefficients d'ondelette n'augmente pas par rapport à la décomposition en ondelette discrète et il n'y a pas de redondance. La figure 1.14 montre




FIG. 1.13 – Décomposition en ondelette d'une image 2D

une décomposition en paquets d'ondelette sur un signal 1D.

Cette approche est utilisée dans [Laine et Fan, 1993]. Les auteurs proposent une décomposition en paquets d'ondelette et calculent l'énergie en chaque sous-bande pour former un vecteur de caractéristiques afin de classifier des textures à l'aide d'un réseau de neurones. Laine et Fan utilisent une extension de cette technique et la comparent à la méthode des frames d'ondelette afin de segmenter des textures de mosaïques [Laine et Fan, 1996]. A partir d'un algorithme de classification non-supervisé (*K-means*), les résultats obtenus s'avèrent de meilleure qualité avec leur méthode en décomposition par paquet.

La décomposition en ondelette par paquet donne plus de détails que nécessaire pour analyser une texture. Afin de corriger ce problème, il faudrait pouvoir récupérer uniquement les caractéristiques intéressantes et discriminantes. Pour cela, il est nécessaire de déterminer quelles sous-bandes doivent ou ne doivent pas être décomposées. Coifman et Wickerhauser présentent une première méthode de sélection pour la décomposition des sous-bandes [Coifman et Wickerhauser, 1992]. Ils proposent de calculer un terme d'entropie pour une sous-bande  $\alpha$ . Il est possible de la calculer de la façon suivante :

$$H_\alpha = - \sum_{i=0}^{N_\alpha} E_i \log E_i \quad (1.40)$$

avec  $E_{\alpha,i}$  l'énergie normalisée du  $i^{eme}$  coefficient d'ondelette de la sous-bande  $\alpha$  et  $N_\alpha$  le nombre de coefficients d'ondelette dans la sous-bande  $\alpha$ . Dans un premier temps, ils effectuent une décomposition complète en ondelette par paquets. Par la suite, ils cherchent à minimiser la somme des entropies des sous-bandes se trouvant au bout de la décomposition. En partant du niveau le plus bas, ils comparent l'entropie du parent de chaque paire de sous-bandes à la somme de l'entropie de ses fils. Si l'entropie du parent est inférieure,




FIG. 1.14 – Décomposition en paquets d'ondelette sur un signal 1D

alors les fils sont supprimés de l'arbre de décomposition. Cette vérification est par la suite appliquée à l'ensemble de l'arbre.

Dans [Chang et Kuo, 1993], les auteurs appliquent l'idée de la décomposition par paquet d'ondelette à l'analyse des textures. La norme L1 moyennée est utilisée pour identifier si une sous-bande  $\alpha$  doit être décomposée ou pas. Voici son expression :

$$E_\alpha = \frac{1}{N_\alpha} \sum_{i=0}^{N_\alpha} |w_{\alpha,i}| \quad (1.41)$$

avec  $w_{\alpha,i}$  le  $i^{eme}$  coefficient d'ondelette de la sous-bande  $\alpha$  et  $N_\alpha$  le nombre de coefficients d'ondelette dans la sous-bande  $\alpha$ . La norme L1 moyennée est calculée pour chaque sous-bande en partant du premier niveau de décomposition. Si pour une sous-bande, nous obtenons une valeur faible, alors celle-ci n'est pas décomposée. Les sous-bandes ayant les normes les plus élevées sont conservées comme caractéristiques de textures.

### 1.2.2.7 Le banc de filtres de Schmid

Dans [Schmid, 2001], l'auteur propose d'utiliser un ensemble d'opérateurs dit générique afin d'analyser les structures et les textures d'une image. L'ensemble de Schmid se compose de 13 filtres invariants à la rotation :

$$F(x, y, \sigma, \tau) = F_0(\sigma, \tau) + \cos\left(\frac{\sqrt{x^2 + y^2}\pi\tau}{\sigma}\right)e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (1.42)$$

avec  $(\sigma, \tau)$  prenant les valeurs suivantes : (2, 1), (4, 1), (4, 2), (6, 1), (6, 2), (6, 3), (8, 1), (8, 2), (8, 3), (10, 1), (10, 2), (10, 3) et (10, 4).  $\tau$  représente le nombre de cycles de la fonction harmonique à l'intérieur de l'enveloppe Gaussienne du filtre. La figure 1.15 présente les différents filtres.




FIG. 1.15 – Les 13 filtres du banc de filtre de Schmid

### 1.2.2.8 Le banc de filtre de Leung-Malik (LM)

L'ensemble LM (figure 1.16) est un banc de filtres à la fois multi-échelle et multi-orientation. Il se compose de 48 filtres construits à partir des dérivées premières et secondes de Gaussiennes selon 6 orientations et 3 échelles, de 8 Laplaciens de Gaussiennes et de 4 Gaussiennes. Dans [Leung et Malik, 2001], les auteurs utilisent ce banc de filtres dans un problème de classification de textures 3D. Rappelons que les textures 3D sont des textures avec des variations de luminosité et de surface. Leur méthode propose de construire un vocabulaire de textons, utilisant l'ensemble LM, afin d'obtenir une description générique des surfaces des textures. Ce vocabulaire est utilisé avec un algorithme de chaînes de markov afin de reconnaître les textures 3D.

### 1.2.2.9 Les bancs de filtres de réponse maximum (MR)

Le banc de filtres MR8 [Caenen et Gool, 2004] est similaire au banc de filtres LM et se compose de 38 filtres : 2 filtres anisotropiques pour la détection de frontières et de bandes selon 6 orientations et 3 échelles  $(\sigma_x, \sigma_y) = \{(1, 3), (2, 6), (4, 12)\}$  pixels, 2 filtres isotropiques avec une Gaussienne et le Laplacien d'une Gaussienne ( $\sigma = 10$  pixels) (Figure 1.17). Cependant, seulement 8 réponses de filtres sont conservées en prenant à chaque échelle, la réponse maximum des filtres anisotropiques selon toutes les orientations. Le nombre de réponses est ainsi réduit de 38 (6 orientations à 3 échelles pour 2 filtres anisotropiques, plus






FIG. 1.16 – Le banc de filtres de Leung-Malik est composé de 48 filtres avec des filtres frontières, tâches et bandes selon plusieurs résolutions et orientations

2 filtres isotropiques) à 8 (3 échelles pour 2 filtres, plus 2 isotropiques). Des sous-ensembles du banc de filtres MR8 sont utilisés avec, par exemple, le banc de filtres MR4 qui est un sous-ensemble du MR8. Ici, une seule échelle est considérée avec  $\sigma_x = 4$  et  $\sigma_y = 12$ .

De façon générale, les filtres invariants à la rotation ne répondent pas de façon précise dans les images contenant des orientations. Les ensembles MR utilisent à la fois des filtres isotropiques et anisotropiques qui permettent d'obtenir des caractéristiques robustes à la fois pour les données orientées et non-orientées. Enfin le fait de conserver uniquement la réponse maximum limite le nombre de caractéristiques en regroupant les informations de textures.

### 1.2.2.10 Bilan

Les méthodes de description de textures fréquentielles fournissent des informations très intéressantes, cependant celles-ci sont souvent difficilement assimilables par les utilisateurs (il est difficile d'interpréter un spectre de Fourier ou un banc de filtre). Pour toutes ces méthodes basées sur des filtres, les caractéristiques de textures sont calculées directement sur les réponses générées pour chaque filtre. Certains chercheurs [Arivazhagan et Ganesan, 2003, Fauzi et Lewis, 2003] utilisent des statistiques simples comme la variance ou la moyenne. D'autres [Unser, 1995] utilisent des caractéristiques statistiques plus complexes comme le contraste, l'énergie, l'entropie, etc. Des statistiques d'ordre deux peuvent également être utilisés : dans [Arivazhagan et Ganesan, 2003] les auteurs calculent des caractéristiques d'Haralick en construisant une matrice de cooccurrence sur des coefficients d'ondelette. Il s'agit encore une fois de caractéristiques difficiles à manipuler pour un humain. Cependant, le point fort de ce type de méthodes est leur faculté à apporter une vision/information multi-niveaux sur le contenu de l'image. Ce point constitue une solution potentielle (bien que partielle) vis à vis des inconvénients mentionnés précédemment pour les méthodes d'analyse de motifs (régionalité et échelle d'observation). Nous retenons donc cet intérêt pour la suite de nos travaux.




FIG. 1.17 – Banc de filtres MR8 composé de 38 filtres à la fois isotropiques et anisotropiques

### 1.2.3 Les méthodes basées sur un modèle

Parmi les modèles les plus utilisés pour l'analyse de textures, nous retrouvons les champs de Markov (MRF), les fractales, les modèles de différenciation fractionnaire et les modèles auto-régressifs. L'estimation des paramètres de ces modèles permet de caractériser les textures d'une image.

#### 1.2.3.1 Les champs de Markov

Les champs de Markov sont beaucoup utilisés dans le domaine de l'analyse et de la synthèse de textures. [Li, 1995, Li, 2001] nous donne un panorama de leur utilisation en vision par ordinateur.

##### *Notion de sites*

Les Champs de Markov décrivent une image  $I$  par l'intermédiaire d'un ensemble fini  $S$  de sites  $s_i$  qui correspondent aux pixels. A chaque site est associé un système de voisinage

$V$ .

Mathématiquement,  $I = \{s_1, s_2, s_3, \dots, s_N\}$  avec  $N$  la taille de l'image, et  $V = \{V_s, s \in I\}$ .

Ce voisinage respecte certaines propriétés qui sont les suivantes :

- $s \notin V_s, \forall s \in I$
- $\forall s, t \in I, s \in V_t \Leftrightarrow t \in V_s$

2	1	2
1	s	1
2	1	2

FIG. 1.18 – Représentation d'un système de voisinage d'ordre 2

A partir de ce voisinage, un système de cliques est construit. Une clique peut être soit un singleton de  $S$ , soit un ensemble de sites voisins (Figure 1.19). Selon le nombre de connexité utilisé, le système de cliques sera différent et fera intervenir plus ou moins de sites. Nous définissons ainsi le voisinage influant sur le niveau de gris du pixel considéré. Les interactions locales entre niveaux de gris de sites voisins peuvent alors s'exprimer comme un potentiel de clique. Si l'on définit  $c$  une clique associée à un potentiel  $U_c$  alors l'énergie globale de l'image s'écrit :

$$U = \sum_{c \in C} U_c \tag{1.43}$$

avec  $C$  l'ensemble des cliques relatives à  $V$ .

L'énergie locale en un site peut alors s'écrire :

$$U_s = \sum_{c \in C/s \in c} U_c \tag{1.44}$$




FIG. 1.19 – Ensemble de cliques pour un système de voisinage d'ordre 2 (8-connexe)

*Modélisation probabiliste*

L'utilisation des champs de Markov en imagerie nécessite une modélisation probabiliste de l'image. Ainsi, une image est considérée comme une réalisation d'un champ aléatoire. Pour chaque site  $s$  de l'image, il existe différentes réalisations  $x_s$  (niveau de gris) possibles pouvant être perçues comme une famille de variables aléatoires  $X = \{X_1, \dots, X_N\}$  indexées sur  $I$ . Chaque variable aléatoire  $X_s$  est à valeur dans  $\Omega$ , l'espace des états.

[Geman et Geman, 1984] donne la définition du champ de Markov 2D suivant :

**Definition 1.2.2.** *X est un champ de Markov 2D sur  $(I, V)$  si :*

- $P(X = x) > 0, \forall x \in \Omega^N$
- $P(X_s = x_s / X_r = x_r, r \in S - \{s\}) = P(X_s = x_s / X_r = x_r, r \in V_s)$
- $P(X_s = x_s / V_s)$  est dépendante de la configuration des voisins et est invariante à la translation

Le premier point représente la propriété de positivité qui garantit l'unicité de la distribution jointe  $P(X = x)$  du champ de Markov. La deuxième propriété traduit le fait que l'influence des autres pixels de  $V$  sur un pixel  $i$  est réduite à l'influence du voisinage de  $i$ .

Cette formulation ne permet pas d'obtenir de façon simple une expression de  $p(X = x)$ . Un champ de Markov est donc généralement caractérisé par une distribution jointe, ce qui est rendu possible par le théorème de Hammersley-Clifford [Besag, 1974, Geman et Geman, 1984]. Celui-ci lie la propriété de localité des champs de Markov avec la propriété de globalité des champs de Gibbs.

**Théorème 1.2.1.** *X est un champ de Markov  $\iff p(X = x)$  est une distribution de Gibbs.*

La définition d'un champ de Gibbs est la suivante :

**Definition 1.2.3.** *Si  $(X, \Omega^N, P)$  est un champ de Markov par rapport au système de voisinage  $V$  alors sa distribution  $P(X = x)$  est une distribution de Gibbs de portée bornée :*

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

avec  $Z = \sum_{X \in \Omega^N} \exp(-U(X))$  une fonction de normalisation appelée fonction de partition de Gibbs.

*Estimation des paramètres des champs de Markov*

Concernant l'estimation des paramètres d'un champ de Markov pour une image, on peut recenser deux grandes familles de problèmes :

- les données dites complètes, avec lesquelles on cherche à retrouver les paramètres d'une réalisation connue d'un champ de Markov. On se retrouve dans cette problématique par exemple lorsque l'on cherche à caractériser une texture via les paramètres d'un champ de Markov.
- les données dites incomplètes, pour lesquelles le champ de Markov recherché est caché, et ses paramètres sont à estimer. On peut citer comme exemple le cas de la segmentation ou bien encore de la restauration d'images.

*Exemple de caractérisation de textures avec le modèle markovien binomial*

Ce modèle est un cas particulier du modèle markovien général et permet une bonne description de variables discrètes telles que le niveau de gris d'un site d'une image. Dans [Cross et Jain, 1983], les auteurs l'utilisent pour synthétiser et caractériser des textures.

D'un point de vue formel, la probabilité conditionnelle d'avoir un niveau de gris  $x_s$  dans le site  $S$  est :

$$p(X_s = x_s | x_t, \forall t \in V_s) = C_{F-1}^{x_s} p^{x_s} (1-p)^{F-1-x_s}$$

avec  $V_s$  le voisinage du site  $S$ . On est ici dans le cas d'une loi binomiale avec une probabilité  $p$  et un nombre de tirage de  $F-1$ ,  $F$  étant le nombre total de niveaux de gris. La probabilité  $p$  qui est un paramètre de la loi binomiale s'exprime de la façon suivante :

$$\frac{p}{1-p} = e^{U_s} \Rightarrow p = \frac{e^{U_s}}{1 + e^{U_s}}$$

avec  $U_s$  dépendant de l'ordre considéré par le modèle, et défini comme une fonction linéaire calculée à partir des niveaux de gris du voisinage au site  $S$ .

La figure 1.18 présente les pixels pris en compte dans un système de voisinage d'ordre 2 (pixels 1 et 2). Dans un modèle d'ordre 1, seuls les pixels labellisés "1" auraient été utilisés. En prenant comme exemple le modèle d'ordre 2 de la figure 1.19,  $U_s$  peut être calculé de la façon suivante :

$$U_s = a + b_1(x_{i,j-1} + x_{i,j+1}) + b_2(x_{i-1,j} + x_{i+1,j}) + b_3(x_{i-1,j-1} + x_{i+1,j+1}) + b_4(x_{i+1,j-1} + x_{i-1,j+1})$$

Les coefficients de pondération  $a$ ,  $b_1$ ,  $b_2$ ,  $b_3$ ,  $b_4$  correspondent alors aux descripteurs de la texture.  $a$  donne une représentation du niveau de gris moyen,  $b_1$  décrit l'homogénéité horizontale,  $b_2$  verticale, et  $b_3$  et  $b_4$  l'homogénéité diagonale.

Une notation vectorielle pour  $U_s$  donnerait :

$$U_s = \theta^T \cdot \Phi \tag{1.45}$$

avec  $\theta^T = [a, b_1, b_2, b_3, b_4]$  et  $\Phi^T = [1, x_{i,j-1} + x_{i,j+1}, x_{i-1,j} + x_{i+1,j}, x_{i-1,j-1} + x_{i+1,j+1}, x_{i+1,j-1} + x_{i-1,j+1}]$ .

Une des façons pour estimer  $\hat{\phi}$  est d'utiliser la méthode du maximum de vraisemblance. Cependant, celle-ci est en pratique extrêmement lente. D'autres méthodes emploient des algorithmes itératifs avec notamment l'algorithme du gradient stochastique [Younes, 1988].

*Cas de la segmentation : Données incomplètes*

Dans le cas de la segmentation, le champ de Markov cherché est caché. Nous disposons d'une image  $y$  qui est une réalisation d'un champ aléatoire  $Y$ . Nous cherchons alors une réalisation  $x$  de l'image segmentée qui peut être modélisée comme un champ de Markov  $X$  appelé champ des étiquettes. Ces deux champs ont des espaces de configurations différents. En effet, dans le champ  $X$ , les étiquettes considérées correspondent aux différentes classes cherchées. Si l'on considère que chaque classe  $i$  a une distribution gaussienne de moyenne  $\mu_i$  et d'écart-type  $\sigma_i$ , alors la probabilité d'avoir un niveau de gris pour une classe donnée s'écrit :

$$P(y_s/x_s = i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(y_s - \mu_i)^2}{2\sigma_i^2}\right) \tag{1.46}$$

La probabilité *a priori* est utilisée pour introduire des contraintes sur la solution. Cette

probabilité dans le cas d'un modèle gaussien s'écrit :

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

$$\text{avec } U(x) = \beta \sum_{(s,t) \in C_2} (x_s - x_t)^2 + \alpha \sum_{s \in S} (x_s - \mu_s)^2 \quad (1.47)$$

Dans  $U$ , le premier terme correspond à un terme de régularisation alors que le deuxième se définit comme un terme d'attache aux données.  $\alpha$  et  $\beta$  permettent de pondérer ces deux expressions.

L'énergie correspondant à la distribution de Gibbs du champ *a posteriori* peut alors s'écrire :

$$U(x/y) = \sum_s \frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} + \log(\sqrt{2\pi}\sigma_{x_s}) + \beta \sum_{(s,t) \in C_2} (x_s - x_t)^2 + \alpha \sum_{s \in S} (x_s - \mu_s)^2 \quad (1.48)$$

Dans cet exemple, nous utilisons le modèle gaussien, mais d'autres modèles de champs de Markov peuvent être utilisés comme le modèle d'Ising [Ising, 1925] ou le modèle de Potts [Wu, 1982].

Pour trouver les états d'énergie minimum, il existe plusieurs estimateurs [Besag, 1986] :

- l'estimateur MAP (maximum *a posteriori*) : avec cet estimateur, on cherche à pénaliser toute différence entre deux configurations. Les algorithmes associés à cet estimateur sont le recuit simulé ainsi que l'algorithme des modes conditionnels itérés (ICM).
- l'estimateur MPM (maximum *a posteriori* marginal) : la fonction de coût associé à cet estimateur pénalise une configuration proportionnellement au nombre de différences entre deux configurations.
- l'estimateur TMP (*Thresholded Posteriori Mean*) : la fonction de coût pénalise la somme des différences entre deux configurations. Si l'on compare avec l'estimateur MPM, elle tient compte non seulement du nombre de différences mais également de leurs valeurs.

Parmi tous les modèles Markoviens, le plus utilisé est le champ de Markov Gaussien (GMRF) [Chellappa et Jain, 1993, Cohen et Cooper, 1987, Chellappa et Chatterjee, 1985]. Dans [Descombes *et al.*, 1999], les auteurs proposent deux modèles markoviens gaussiens, l'un étant isotrope et l'autre anisotrope. Pour chacun de ces modèles, une méthode d'estimation est utilisée, la première étant fondée sur la construction de matrices de probabilités conditionnelles, la deuxième sur la théorie de la renormalisation. [Krishnamachari et Chellappa, 1997] utilisent la méthode GMRF pour modéliser l'image à plusieurs résolutions en faisant l'hypothèse que les variables aléatoires sont indépendantes quelle que soit la résolution. Les propriétés de Markov étant perdues pour des résolutions trop grossières, elles ne peuvent pas être approximées par des champs aléatoires de Markov. Ils proposent alors une approximation avec les Champs de Markov. Dans le même principe, [Comer et Delp, 1999] utilisent un modèle gaussien auto-régressif. Cependant, leur méthode prend en compte la corrélation entre deux niveaux adjacents de résolution.

### 1.2.3.2 Les fractales

Les fractales ont été utilisées avec beaucoup de succès pour synthétiser les textures naturelles. Sa grande capacité à caractériser la rugosité fait de la dimension fractale un candidat naturel pour la mesure de caractéristiques de textures. Mandelbrot [Mandelbrot, 1983, Mandelbrot, 1977] est le premier à relater l'existence de la géométrie fractale dans le monde.

Dans la géométrie classique, un objet à une dimension est symbolisé par une ligne, un objet à deux dimensions un plan et un objet à trois dimensions par un volume. De cette façon la dimension des objets est un nombre entier allant de 0 jusqu'à  $n$ . La géométrie fractale peut être définie comme une notion complémentaire à la géométrie euclidienne. Celle-ci définit la manière dont un objet occupe l'espace euclidien à travers un nombre, généralement non entier, qui caractérise un espace où la dimension de l'objet prend une valeur finie non nulle. La courbe de Koch constitue un bon exemple pour mieux comprendre la signification de ce nombre. Dans [Mandelbrot, 1977], cette courbe est construite de la façon suivante : en partant d'un segment de longueur unité, le tiers central est retiré et remplacé par un triangle équilatéral sans base (Figure 1.20). Par rapport au segment initial, la longueur de la courbe augmente en passant de  $3/3$  à  $4/3$ . En continuant cette opération sur chacun des segments de longueur  $1/3$ , la longueur de la courbe continue d'augmenter avec  $(4/3)^2$ . Si cette opération est répétée un nombre infini de fois, alors nous pouvons construire la courbe de Koch de longueur infinie.

La mesure de la longueur de cette courbe dépend de l'étalon choisi. Pour un étalon de 1 la longueur de la courbe sera de 1, pour un étalon de  $1/3$  la longueur sera de  $4/3$  etc. Soit  $L(\delta)$  la longueur mesurée avec un segment de mesure  $\delta$ . Avec un étalon de longueur  $\delta/3$ , la longueur  $L(\delta/3)$  sera égale à la longueur mesurée avec un étalon de longueur  $\delta$  multipliée par  $4/3$ . La longueur de la courbe de Koch à la  $n^{ième}$  étape peut donc être exprimée de la façon suivante :

$$L(\delta) = \left(\frac{4}{3}\right)^n \quad (1.49)$$

avec  $\delta = \left(\frac{1}{3}\right)^n$  la longueur d'un étalon d'où  $n = -\frac{\text{Log}\delta}{\text{Log}3}$  La longueur de la courbe peut alors être exprimée comme suit :

$$L(\delta) = \left(\frac{4}{3}\right)^{-\frac{\text{Log}\delta}{\text{Log}3}} \quad (1.50)$$

D'après la loi de Richardson, nous avons :

$$L(\delta) = \left(\frac{4}{3}\right)^{-\frac{\text{Log}\delta}{\text{Log}3}} = \delta^{1-D} \quad (1.51)$$

En prenant le logarithme de la dernière égalité, nous trouvons :

$$D = \frac{\text{Log}4}{\text{Log}3} = 1.2628 \quad (1.52)$$

Ce nombre D, appelé dimension fractale, peut être considéré comme la dimension de la courbe de Koch. Pour cette courbe, le quart de l'objet est identique à l'objet initial s'il est dilaté 3 fois. Or la valeur de D est le logarithme de 4 sur le logarithme de 3.

Un concept important concernant les fractales est l'auto-similarité. Un objet invariant par la transformation d'un vecteur  $r$  est dit auto-affine de vecteur  $r$ . De plus, si les composantes du vecteur  $r$  sont égales, alors nous pouvons parler d'auto-similarité. Par exemple la courbe de Koch est auto-similaire de vecteur  $r = (3, 3)$ . Si nous prenons le quart gauche et que nous le dilatons, nous retrouvons cette même courbe. L'auto-similarité d'une structure, c'est donc le fait qu'elle puisse être réduite à des éléments plus petits qui ne sont que des répliques de la structure initiale.




FIG. 1.20 – Construction de la courbe de Koch

Dans [Soille et Rivest, 1996], les auteurs proposent un état de l'art sur les méthodes d'estimation de la dimension fractale. Celles-ci peuvent être divisées en deux familles comprenant les méthodes d'estimations géométriques et les méthodes stochas-



tiques. Parmi les méthodes d'estimations géométriques, nous pouvons citer les méthodes d'analyse morphologique [Peleg *et al.*, 1984], la méthode des triangles plans [Clarke, 1986], la méthode de l'élément structurant plat et enfin la méthode dite de *Box counting* [Sarkar et Chaudhuri, 1994]. Les méthodes stochastiques permettent d'estimer la dimension fractale en analysant le spectre de puissance obtenu à partir de la transformée de Fourier [Soille et Rivest, 1996] mais également en utilisant les variogrammes [Dubuc *et al.*, 1989].

La méthode du *Box counting* est l'une des plus utilisées grâce à sa simplicité de mise en œuvre ainsi que pour son faible coût en temps d'exécution. L'image est binarisée puis découpée en un quadrillage de carrés élémentaires de taille  $\epsilon$ . Par la suite, le nombre de carrés  $N_\epsilon$  nécessaires à l'approximation de la texture est compté. Cela revient à faire la somme des boîtes contenant au moins un pixel noir. La *box dimension* d'une zone considérée  $X$  est alors donnée par :

$$D(X) = \lim_{\epsilon \rightarrow 0} \frac{\log[N_\epsilon(X)]}{\log \epsilon} \quad (1.53)$$

Afin de déterminer cette limite, plusieurs valeurs de  $\epsilon$  sont considérées. La pente de régression linéaire de la courbe ainsi obtenue correspond à la dimension fractale.

En complément de cette dimension, certains auteurs proposent d'ajouter une mesure caractérisant l'homogénéité d'une distribution fractale. Cette mesure est nommée lacunarité. Avec la méthode des *box counting*, il est possible de l'estimer de la façon suivante :

$$\Lambda = \frac{E[M^2(\epsilon)] - E^2[M(\epsilon)]}{E^2[M(\epsilon)]} \quad (1.54)$$

avec  $E$  l'espérance mathématique,  $M$  la masse fractale définie par  $M(\epsilon) = \sum_{m=1}^{\epsilon} m PR_{G(f)}(m, \epsilon)$ .  $PR_{G(f)}(m, \epsilon)$  la probabilité de trouver un point de l'objet fractal  $G(f)$  dans un carré de taille  $\epsilon$  (probabilité de trouver un pixel noir pour le cas d'une texture).

Une des adaptations les plus connues de la méthode *box counting* est la méthode *Differential Box Counting* proposée dans [Sarkar et Chaudhuri, 1992, Sarkar et Chaudhuri, 1994]. Cette méthode propose des solutions à un certain nombre de limitations de *box counting* et permet notamment de travailler directement sur les images en niveaux de gris.

[Pentland, 1984] est l'un des premiers à utiliser la dimension fractale pour la segmentation. Il estime une dimension fractale omnidirectionnelle sur des blocs de pixels de taille  $8^2$  en utilisant la méthode des spectres de puissance. Il arrive à une segmentation grossière à l'intérieur des régions texturées et non-texturées. De la même façon, Medioni et Yasumoto utilisent une dimension fractale omnidirectionnelle pour segmenter une image contenant plusieurs textures [Medioni et Yasumoto, 1984]. Cependant les résultats obtenus ne sont pas satisfaisants. Pour eux la dimension fractale n'est pas suffisante pour caractériser tous les aspects d'une texture et permet de séparer uniquement les textures ayant une rugosité suffisamment éloignée.

Pour améliorer les résultats, de nouveaux paramètres comme la lacunarité doivent être ajoutés. Les auteurs dans [Keller *et al.*, 1989] utilisent la lacunarité ainsi qu'une estimation omnidirectionnelle de la dimension fractale. Leurs résultats montrent que ce paramètre

permet une amélioration des résultats de segmentation des textures.

Tout comme dans la plupart des méthodes d'analyses de textures, il est possible d'utiliser la notion de direction afin d'estimer la dimension fractale. [Mosquera *et al.*, 1992] estiment la dimension fractale selon quatre directions avec les deux diagonales, la direction verticale et horizontale. Dans [Jeannane, 1995], l'auteur utilise un modèle non-stationnaire fractal dans lequel il analyse des lignes de niveau de gris d'une image dans une direction donnée. Dans [Lopes et Betrouni, 2009], les auteurs présentent un état de l'art sur les méthodes d'analyse fractale et multifractale ainsi qu'une description de leur application dans le domaine médical. Les multifractales sont décrites comme une extension des fractales. Un objet multifractal est plus complexe dans le sens où il est toujours invariant par translation. Dans [Lopes et Betrouni, 2009], les méthodes permettant l'approximation du spectre multifractal sont réparties en deux classes : les méthodes dites *box counting* et les méthodes basées ondelettes. Les méthodes de la première classe sont basées sur le même principe que les méthodes *box counting* utilisées pour l'estimation de la dimension fractale. Une image est découpée avec des boîtes de tailles variables et une mesure normalisée est calculée à l'intérieur de chacune d'elles. Les méthodes basées ondelettes utilisent la transformée en ondelette d'une image comme une boîte "oscillante" afin de représenter ses différents composants. Certaines méthodes utilisent la transformée en ondelette discrète, d'autres utilisent la transformée en ondelette continue.

### 1.2.3.3 Bilan

Le point commun à toutes ces méthodes basées sur un modèle est qu'il est possible de les utiliser pour générer des textures ainsi que pour les analyser. Leur utilisation en caractérisation et segmentation peut être considérée comme plus difficile de par la nécessité de définir de nombreux paramètres complexes à manipuler. De plus, les temps de calcul de ce genre de méthodes sont parfois très importants. Ces méthodes semblent donc plus difficilement utilisables dans le cadre de la mise en place d'un système d'analyse de textures volumétriques se voulant générique et facilement manipulable par les utilisateurs.

### 1.2.4 Les méthodes basées sur une analyse spatiale et statistique des intensités de niveau de gris

Ces méthodes sont basées sur des évaluations quantitatives de la distribution des niveaux de gris définissant une texture. Ces approches ne cherchent pas à isoler un motif de base mais permettent d'évaluer les propriétés statistiques d'une région ou d'un certain voisinage autour d'un pixel.

#### 1.2.4.1 Statistiques du premier ordre

Les statistiques du premier ordre mesurent la probabilité d'observer un niveau de gris à un emplacement aléatoire d'une image. Elles sont calculées à partir de l'histogramme des intensités. Parmi les attributs du premier ordre nous retrouvons :

- les moments d'ordre  $k$  :  $\mu_k = \sum_n n^k p(n)$
- les moments centrés d'ordre  $k$  :  $\tilde{\mu}_k = \sum_n (n - \mu_1)^k p(n)$  avec :

- la moyenne des niveaux de gris :  $\mu_1$
- la variance :  $\sigma^2$
- le biais :  $\frac{\tilde{\mu}_3}{\sigma^3}$
- l'aplatissement :  $\frac{\tilde{\mu}_4}{\sigma^4} - 3$
- l'énergie :  $\sum_n |p(n)|^2$
- l'entropie :  $-\sum_n p(n) \log p(n)$
- le contraste :  $\frac{\max(n) - \min(n)}{\max(n) + \min(n)}$
- la dynamique :  $\max(n) - \min(n)$
- le coefficient de variation :  $\frac{\mu}{\sigma}$
- l'exposant de Holder [Pentland, 1984]

$p(n)$  correspond à la probabilité empirique du niveau de gris  $n$  dans l'histogramme des intensités. Pour améliorer la qualité des statistiques, il est conseillé de requantifier l'histogramme des intensités. En effet, le fait de considérer 256 niveaux de gris réduit le nombre d'occurrences moyen par pixel. Si nous effectuons des mesures dans un voisinage restreint, les statistiques mesurées risquent de devenir peu significatives.

#### 1.2.4.2 Caractéristiques d'auto-corrélation

La fonction d'auto-corrélation permet d'évaluer si une texture est plutôt fine ou grossière. La figure 1.22 présente plusieurs exemples de fonctions d'auto-corrélation calculées sur une texture large, une texture fine et une texture périodique. Pour des primitives larges, la fonction d'auto-corrélation décroît lentement alors que pour des primitives fines, elle décroît rapidement. Enfin, pour des textures périodiques, la fonction d'auto-corrélation croît et décroît périodiquement. La fonction d'auto-corrélation permet également d'étudier la présence d'orientation dans une texture [Bres, 1994].

Formellement, la fonction d'auto-corrélation 2D se définit de la façon suivante :

$$x(p, q) = \frac{M \cdot N}{(M - p)(N - q)} \cdot \frac{\sum_{i=1}^{M-p} \sum_{j=1}^{N-q} f(i, j) \cdot f(i + p, j + q)}{\sum_{i=1}^M \sum_{j=1}^N f^2(i, j)} \quad (1.55)$$

avec  $M$ ,  $N$  les dimensions de l'image,  $(p, q)$  un vecteur permettant de définir un déplacement par rapport à la position  $(i, j)$ , et  $f(i, j)$  l'intensité à la position  $(i, j)$ .

Cette fonction dispose de nombreuses propriétés :

- elle a un maximum à l'origine égal à 1
- elle est bornée à l'intervalle  $[-1, +1]$
- elle est paire
- si elle possède un autre maximum égal à 1 en un autre point  $P$ , alors elle possède une infinité de maxima aux positions  $nP$ , et elle est périodique de période  $P$ , ainsi que la fonction  $f$  elle-même
- il existe des relations simples entre les dérivées de la fonction d'auto-corrélation et les fonctions d'auto-corrélation des dérivées de  $f$

La fonction d'auto-corrélation est également liée au spectre de puissance de la transformée de Fourier. En effet le théorème de Wiener-Kinchine (<http://mathworld.wolfram.com/PlancherelsTheorem.html>) établit que la fonction d'auto-corrélation est la transformée de Fourier du spectre de densité de puissance (Figure 1.21). Sur cette base, la rose des

directions utilise la fonction d'auto-corrélation pour déterminer l'orientation et l'anisotropie d'objets ou de textures [Bres, 1994].

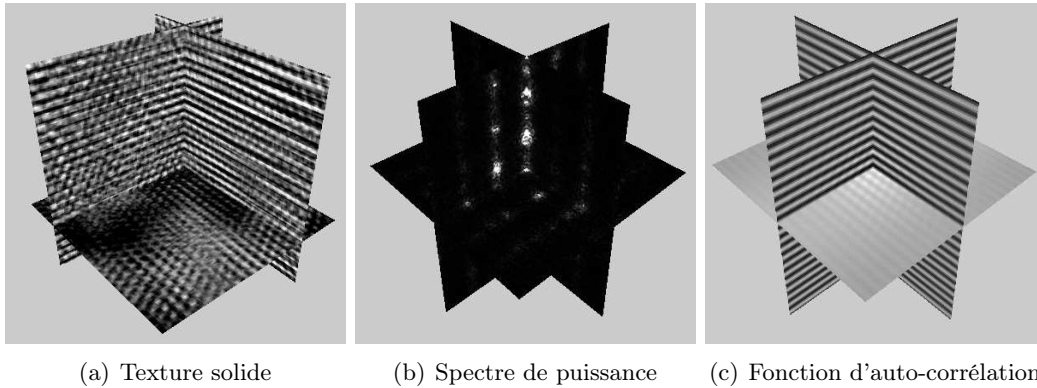


FIG. 1.21 – Fonction d'auto-corrélation calculée à partir du spectre de puissance d'une texture volumétrique

Une extension des fonctions d'auto-corrélations sont les fonctions d'auto-corrélations d'ordre  $N$ . Elles sont définies de la façon suivante :

$$x(a_1, a_2, \dots, a_N) = \int f(r)f(r + a_1)\dots f(r + a_N)dr \quad (1.56)$$

avec  $f(r)$  l'intensité du pixel  $r$  et  $a_1, a_2, \dots, a_N$   $N$  déplacements. [Otsu et Kurita, 1988] proposent une adaptation locale de cette approche appelée *High order local autocorrelation features* (HLAC). Cependant, cette méthode utilise au second ordre et reste très locale puisqu'elle utilise à un masque de dimension  $3^2$ . [Kreutz *et al.*, 1996] proposent de calculer des caractéristiques sur une région plus large ( $5 \times 5$ ). Le problème est que cette méthode génère un nombre de caractéristiques importantes à cause du grand nombre de masques possibles. En effet, les caractéristiques sont calculées en scannant l'image avec les différents masques et en calculant les sommes des produits des pixels correspondants. D'autres méthodes utilisent une structure d'image en pyramide [Kurita *et al.*, 1992]. Plus récemment, [Toyoda et Hasegawa, 2007] proposent une extension de HLAC pour la classification de textures et la reconnaissance de visages. Cette méthode permet de prendre en compte des ordres plus importants (jusqu'à l'ordre 8) et utilise également le principe de multi-résolution.

### 1.2.4.3 Les Matrices de Cooccurrence

[Haralick *et al.*, 1973, Haralick, 1979] proposent d'extraire des statistiques à partir d'une matrice de cooccurrence (GLCM) afin de caractériser une texture. Les matrices de cooccurrence d'Haralick, encore appelées matrices de dépendance spatiale des niveaux de gris, utilisent les statistiques d'ordre 2 et permettent de déterminer la fréquence d'apparition d'un motif formé de deux pixels séparés par une certaine distance  $d$  dans une direction particulière  $\theta$ .

Cette matrice est une matrice carrée de taille  $n^2$  où  $n$  correspond au nombre des niveaux de

## 1.2. MÉTHODES D'EXTRACTION DE CARACTÉRISTIQUES DE TEXTURES

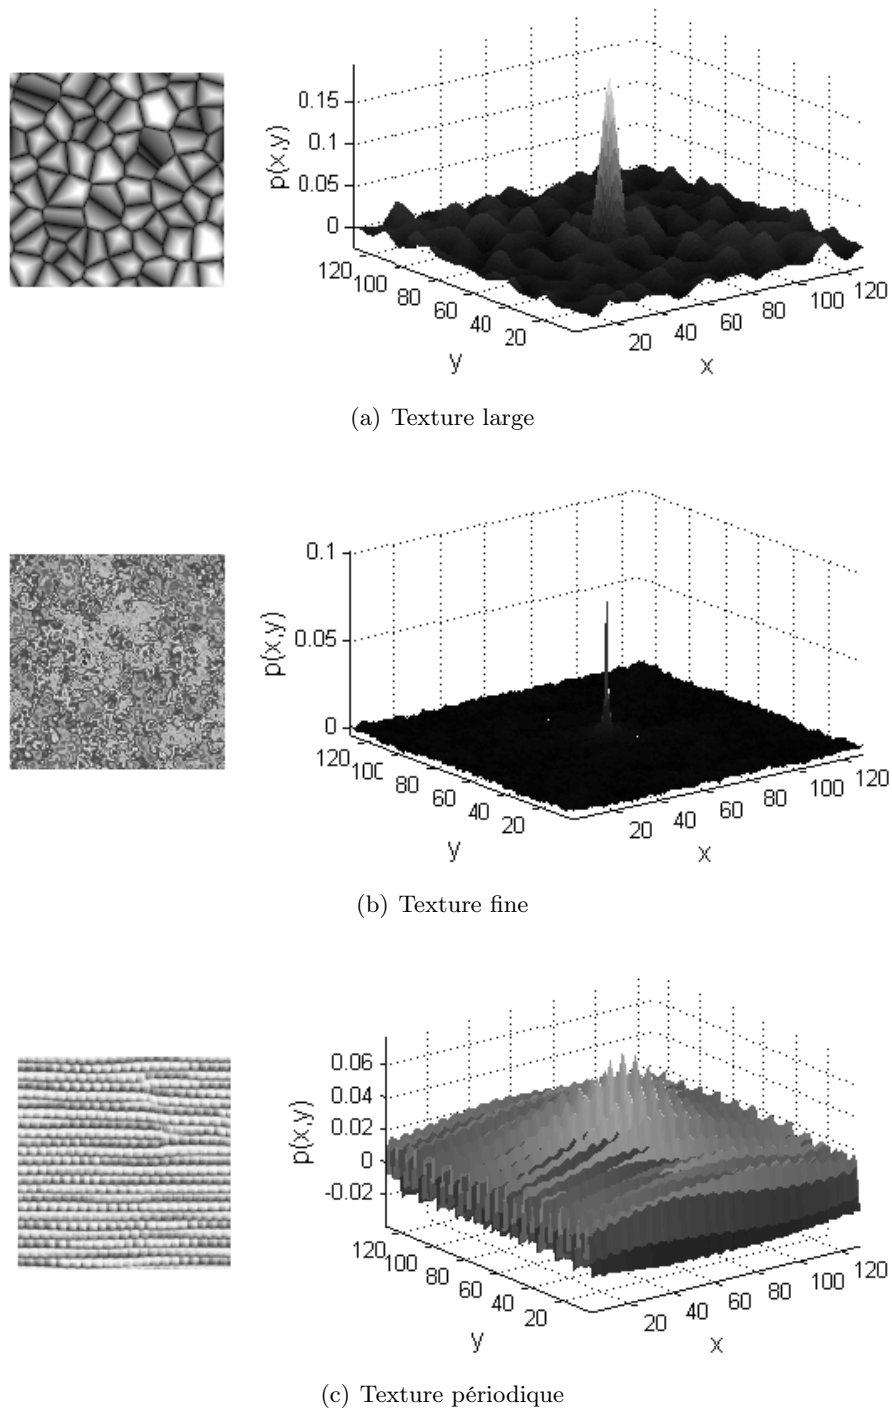


FIG. 1.22 – Exemple de fonctions d'auto-corrélation

gris de l'image. Généralement les niveaux de gris de l'image sont requantifiés (16, 32 ou 64 niveaux de gris) ce qui permet d'avoir un temps de traitement plus restreint. Également,

la requantification permet d'avoir un nombre d'occurrences moyen plus important pour chaque paire de niveaux de gris de la matrice. La normalisation de cette matrice produit une distribution de probabilité. Pour une image  $I$ , une matrice de cooccurrence des niveaux de gris normalisés  $P_v$  pour un vecteur de séparation donné  $v = (v_x, v_y)$  est définie par ses composantes  $P_v(i, j)$  données par l'expression suivante :

$$P_v(i, j) = \frac{\#\{(a, b) : I(a, b) = i, I(a + v_x, b + v_y) = j\}}{\#\{I\}} \quad (1.57)$$

avec  $\#$  la fonction cardinale,  $I(a, b)$  le niveau de gris de l'image  $I$  aux coordonnées  $(a, b)$  et  $i, j \in \{1, 2, \dots, n\}$

[Haralick, 1979] suggère de calculer des matrices de cooccurrence avec différentes directions et d'en faire la moyenne. De cette façon une matrice de cooccurrence peut être un descripteur de textures invariant à la rotation.

La figure 1.23 présente différentes matrices de cooccurrence de niveaux de gris obtenues à partir de plusieurs textures de Brodatz. Celles-ci sont définies sur 16 niveaux de gris et calculées selon le vecteur de séparation  $v = (1, 0)$ . Plus une zone est claire, et plus le couple correspondant de niveaux de gris est présent.

A partir de cette matrice, il est possible de calculer plusieurs caractéristiques [Haralick *et al.*, 1973, Haralick, 1979]. Parmi les plus fréquemment utilisées, nous retrouvons : la moyenne, la variance, le contraste, l'énergie (second moment angulaire), l'entropie, la corrélation, l'homogénéité et l'uniformité. Dans l'annexe A, nous présentons les caractéristiques d'Haralick que nous utilisons par la suite dans cette thèse.

Un certain nombre de variations des matrices de cooccurrence a été proposé dans la littérature. Une matrice de cooccurrence multidimensionnelle généralisée est présentée dans [Kovalev et Petrou, 1996]. Ils proposent d'utiliser des matrices à  $N$  dimensions, ce qui permet de mesurer le nombre d'occurrences d'attributs comme les niveaux de gris ou la magnitude d'un gradient local. Il est également possible d'associer des relations aux éléments de données. Cette variation des matrices de cooccurrence est utilisée dans plusieurs domaines et notamment dans le domaine médical : l'analyse d'images IRM du cerveau [Kovalev *et al.*, 2001], la détection des effets de l'âge et du sexe sur l'asymétrie structurelle du cerveau [Kovalev *et al.*, 2003a], la détection des patients schizophrènes [Kovalev *et al.*, 2003b], la mesure de l'anisotropie d'une texture [Kovalev *et al.*, 1999] etc.

#### 1.2.4.4 Les filtres de convolution

Les filtres de convolution sont utilisés comme des fenêtres glissantes permettant d'extraire les mesures désirées dans une image. Selon les formes présentes (frontières horizontales, verticales, diagonales, bulles etc.) ces opérateurs donneront en résultat des réponses différentes. Ces filtres sont représentés en discret sous forme de grilles de taille  $2^2, 3^2, 5^2, \dots$  en 2D,  $2^3, 3^3, 5^3, \dots$  en 3D.

[Laws, 1980b] propose d'utiliser un ensemble de filtres construits à partir de 3 vecteurs comprenant :  $[-1 \ 0 \ 1]$  utilisé pour les frontières,  $[1 \ 2 \ 1]$  utilisé pour moyenner,  $[-1 \ 2 \ -1]$  utilisé pour détecter les taches. En utilisant ces 3 vecteurs, ces filtres peuvent facilement être étendus à la 3D. Cependant, le nombre de combinaisons possibles en 3D est important,

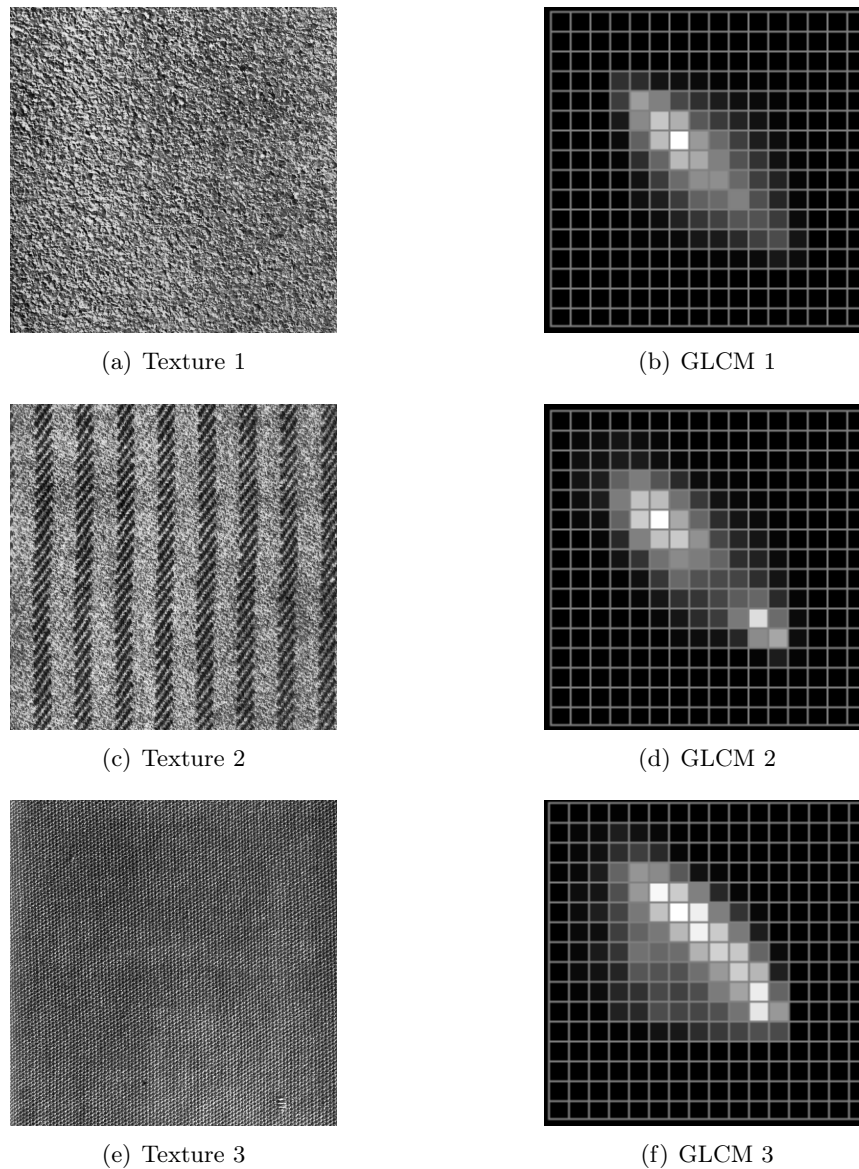


FIG. 1.23 – Exemple de matrices de cooccurrences de niveaux de gris sur des textures de Brodatz

ce qui pose problème pour le temps de génération des caractéristiques mais aussi pour le choix des caractéristiques discriminantes. Dans [Lang *et al.*, 1991], l'auteur les utilise pour analyser les structures fibreuses dans les muscles à partir d'images microscopiques confocales.

Les filtres différentiels sont également utilisés en analyse de textures. La dérivée partielle en chaque orientation  $(x, y, z)$  est obtenue par une simple soustraction avec

$\begin{bmatrix} +1 & -1 \end{bmatrix}$  ou  $\begin{bmatrix} +1 \\ -1 \end{bmatrix}$ . L'opérateur de Roberts permet d'obtenir les différences sur les

## 1.2. MÉTHODES D'EXTRACTION DE CARACTÉRISTIQUES DE TEXTURES

diagonales  $\begin{bmatrix} +1 & 0 \\ 0 & -1 \end{bmatrix}$ ,  $\begin{bmatrix} -1 & 0 \\ 0 & +1 \end{bmatrix}$ . D'autres opérateur comme Sobel  $\begin{bmatrix} +1 & 0 & -1 \\ +2 & 0 & -2 \\ +1 & 0 & -1 \end{bmatrix}$ ,

$\begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$  ou Prewit  $\begin{bmatrix} +1 & 0 & -1 \\ +1 & 0 & -1 \\ +1 & 0 & -1 \end{bmatrix}$ ,  $\begin{bmatrix} +1 & +1 & +1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$  permettent de calculer

le gradient. Le filtre de Zucker-Hummel [Zucker et Hummel, 1981]

$$\begin{bmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{3}} \\ \frac{1}{\sqrt{2}} & 1 & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{3}} \end{bmatrix},$$

$\begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$ ,  $\begin{bmatrix} -\frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{3}} \\ -\frac{1}{\sqrt{2}} & -1 & -\frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{3}} \end{bmatrix}$  est également un opérateur de calcul du gradient et celui-

ci est utilisé dans de nombreuses applications d'analyse de textures [Kovalev *et al.*, 2001, Kovalev *et al.*, 2003a, Kovalev *et al.*, 1999, Kovalev *et al.*, 2003b].

Dans [Bernasconi *et al.*, 2001], l'auteur utilise le module du gradient comme une mesure de textures afin d'analyser les transitions entre la matière grise et la matière blanche dans des images IRM du cerveau. [Randen *et al.*, 2000] utilisent le gradient afin de déterminer les attributs de textures d'orientation et d'enfoncement dans des applications sismiques. Pour cela, ils calculent une matrice de cooccurrence locale construite à partir du gradient plutôt que sur l'image initiale.

### 1.2.4.5 Bilan

La description de textures à partir de telles analyses statistiques constitue le moyen le plus fréquemment utilisé, quel que soit le type d'images à traiter (notamment pour ce qui concerne les matrices de cooccurrence d'Haralick). Nous pensons que ceci est dû à la simplicité de mise en œuvre et de compréhension des concepts manipulés. De même, les caractéristiques produites (entropie, homogénéité, moyenne, contraste, etc.) correspondent à des notions fréquemment manipulées et assimilables par les utilisateurs. Par contre, ces méthodes paraissent assez sensibles au paramétrage utilisé qui doit être adapté pour chaque type d'images et nécessite d'avoir d'importantes connaissances *a priori* sur les textures à traiter. Ce point négatif en contradiction avec nos objectifs de généralité ne nous incitera pas à mettre en œuvre ce type de méthodes.

## 1.2.5 Vers une caractérisation plus visuelle des textures

D'autres auteurs proposent de combiner plusieurs attributs de textures afin d'approximer le système visuel humain [Tamura *et al.*, 1978, Amadasun et King, 1989]. En effet, le système visuel humain est efficace sur tous types de textures même en l'absence d'un contexte favorable. Dans [Tamura *et al.*, 1978], les auteurs proposent de décrire une texture à partir de 6 caractéristiques quantifiables par un être humain : la rugosité, le contraste, la directionnalité, la linéarité, la finesse et la régularité. Afin de tester les méthodes de calcul proposées pour chaque caractéristique, ils proposent de construire un ensemble d'expérimentations psychologiques et de les comparer. Pour cela, ils demandent à 46 sujets de clas-



sifier (d'ordonner) différentes textures selon les différentes caractéristiques proposées. Des tests de corrélation montrent une très bonne correspondance de leurs caractéristiques avec la perception humaine. Ils concluent également en disant que la rugosité, la directionnalité et le contraste sont des caractéristiques importantes pour la séparabilité des textures. De la même façon, [Amadasun et King, 1989] définissent plusieurs caractéristiques de textures avec la finesse, le contraste, *busyness* (correspondant à la rugosité) et la complexité (mesure du nombre de primitives de base). En utilisant les caractéristiques proposées par Tamura et al ainsi que Amadasun et King, Ravishankar Rao et Lohse dans [Rao et Lohse, 1993a] proposent d'identifier les plus pertinentes. Pour cela, ils demandent à 20 sujets d'effectuer une classification sur 30 textures et de les regrouper dans autant de classes que nécessaire. A partir de cette classification, ils construisent une matrice de similarité et en concluent qu'une texture peut être classifiée à partir de trois composantes : la répétition, l'orientation et la complexité. Dans [Rao et Lohse, 1993b], les mêmes auteurs, présentent une série de tests identiques à ceux présentés dans l'article précédent. La différence est qu'ils utilisent à la fois des données avec et sans métriques et le nombre de textures 2D devient plus important. Les résultats présentés affinent ceux décrits dans [Rao et Lohse, 1993a] et les auteurs proposent une représentation des textures selon trois dimensions : "répétitive contre non-répétitive", "fort-contraste et non-directionnel contre faible-contraste et directionnel" et "Granuleux, grossier et faible-complexité contre non-granuleux, fin et forte-complexité". Cette modélisation présente l'avantage de décrire une texture de façon très simple avec une métrique sur trois dimensions, chacune d'entre elles étant représentative d'une combinaison de caractéristiques. Cependant, même s'il est très probable qu'une texture fine ait une forte complexité, il est également hautement probable qu'une texture soit séparable selon ces deux caractéristiques. Nous pouvons alors nous demander si une caractérisation sur trois dimensions est suffisamment précise pour séparer deux textures différentes ayant des propriétés similaires.

Les différents travaux semblent montrer qu'il est plus efficace, pour produire ces descripteurs, de combiner des méthodes de caractérisation de textures appartenant aux différentes familles que nous avons identifiées préalablement. [Arivazhagan et Ganesan, 2003] proposent d'utiliser à la fois les matrices de cooccurrence des niveaux de gris (méthode statistique) et la décomposition en ondelette discrète (méthode fréquentielle). Parmi l'ensemble des méthodes d'analyse de textures comparées dans [Stachowiak *et al.*, 2005], cette dernière se révèle être la plus performante.

Parmi les "caractéristiques visuelles", la rugosité et la directionnalité sont très souvent utilisées. Dans la suite, nous proposons une revue des méthodes principalement utilisées pour les estimer.

### 1.2.5.1 Méthodes de calcul de la rugosité

Une texture rugueuse est une texture dont la surface présente différentes aspérités. Dans la littérature, plusieurs méthodes sont utilisées pour estimer la rugosité présente dans une image. Parmi elles, nous pouvons citer les méthodes d'estimation de la dimension fractale dont nous avons déjà discuté à la section 1.2.3.2. En effet, la dimension fractale correspond à la perception humaine de la rugosité d'une image [Novianto *et al.*, 2003]. Dans

[Soille et Rivest, 1996], les auteurs décrivent plusieurs méthodes pour estimer la dimension fractale. L'une des méthodes les plus connues est la méthode *Differential Box Counting* proposée dans [Sarkar et Chaudhuri, 1992, Sarkar et Chaudhuri, 1994]. En terme de temps d'exécution cette approche est la plus efficace. [Tsai et Tseng, 1999] proposent d'estimer la rugosité d'une surface en utilisant le spectre de puissance de la transformée de Fourier. Celui-ci est alors divisé en plusieurs régions anneaux. Une caractéristique est calculée pour chacune d'entre elles afin d'obtenir un vecteur représentatif de la rugosité de l'image de départ. De nombreuses mesures statistiques ont également été proposées pour déterminer la rugosité d'une image. Dans [Al-Kindi *et al.*, 1992], les auteurs mesurent la rugosité d'une surface en se basant sur l'espacement mais aussi la cardinalité des pics de niveaux de gris sur une ligne de l'image. Dans [Luk et Huynh, 1987], il est proposé d'utiliser la moyenne et la variance de l'histogramme des niveaux de gris afin de caractériser la rugosité. De la même façon, [Zhongxiang *et al.*, 2008] utilisent l'histogramme des niveaux de gris pour en déduire la rugosité à partir de 4 caractéristiques : la moyenne, la variance, la racine carrée moyenne de la déviation de la surface représentant l'amplitude de la surface, la pente des pics.

### 1.2.5.2 Méthodes de caractérisation de la directionnalité

De nombreuses approches ont été développées pour estimer les orientations principales d'une image. Parmi celles-ci, nous retrouvons notamment les approches dérivatives. [Lyvers et Mitchell, 1988] proposent une étude de ce type de méthodes et font une distinction sur les filtres gradients selon que leur réponse impulsionnelle est finie (FIR) ou infinie (IIR). Parmi les filtres FIR, les plus populaires sont les filtres de Sobel ou de Prewitt. Néanmoins, ce type de filtres montre une certaine sensibilité au bruit de part la faible taille de leur support. Concernant les filtres IIR, leur construction se fait souvent à partir de dérivées de Gaussienne [Kass et Witkin, 1987, Rao, 1990, Rao et Schunck, 1991, Rao et Jain, 1992]. Ces approches sont peu sensibles au bruit, cependant elles ne garantissent pas une estimation précise des orientations.

D'autres méthodes comme les tenseurs d'orientations permettent d'obtenir des informations sur l'orientation à partir de la matrice de covariance du champ local de gradient [Kass et Witkin, 1987, Rao, 1990, Rao et Schunck, 1991, Rao et Jain, 1992]. D'après [Germain, 2007], ces approches s'éloignent de la notion d'estimation de l'orientation locale dans le sens où elles calculent des statistiques spatiales sur des gradients locaux.

Les méthodes basées sur les statistiques d'ordre 2 permettent également d'estimer l'orientation. En effet, avec les matrices de cooccurrence [Haralick *et al.*, 1973, Haralick, 1979], il est possible de retrouver la structure de placement des primitives d'une texture. Cependant, le nombre de matrices à générer est très important, ce qui augmente grandement les temps d'exécution. Les histogrammes des différences des niveaux de gris étendus [Chetverikov, 1995] sont une autre alternative des statistiques d'ordre 2 pour le calcul de l'orientation. Néanmoins, tout comme les matrices de cooccurrence, cette méthode engendre un coût calculatoire élevé.

Proposé par [Bres, 1994], la rose des directions d'une image peut être définie comme une courbe polaire permettant de mesurer la force des orientations à partir de la fonction d'auto-corrélation de cette même image. Dans [Eglin, 1998], l'auteur définit la fonction

d'auto-corrélation comme étant le regroupement de l'ensemble des valeurs que l'on peut obtenir en faisant la somme de tous les produits des niveaux de gris. Ainsi un point de la fonction d'auto-corrélation correspond à la somme des produits de l'ensemble des pixels d'une image pour une translation donnée. De cette façon, une image est explorée selon plusieurs directions, ce qui permet par la fonction d'auto-corrélation de mettre en évidence les directions principales. Pour étudier les orientations d'une image, cette méthode se révèle comme étant très précise. Cependant, dans un faible voisinage, cette méthode est sensible au bruit. De plus, dans le cadre d'une segmentation, l'exploration des fonctions d'auto-corrélation sur chacun des pixels/voxels de l'image se révèle coûteuse en temps de calcul. Les bancs de filtres sont également utilisés pour l'étude des orientations dans les images. Contrairement aux méthodes dérivatives, ils permettent de détecter les orientations locales multiples. Il existe plusieurs types de filtres orientés avec par exemple les filtres en quadrature [Granlund et Knutsson, 1995], les filtres de Gabor [Chen *et al.*, 2000], ou les filtres Steerable [Sommer *et al.*, 1998]. Cependant, la précision de ce type de méthodes dépend beaucoup de leurs paramètres, à savoir le nombre de filtres, la taille des masques, etc. Dans certains cas d'application, elles peuvent également se révéler coûteuses en temps de calcul.

#### 1.2.5.3 Bilan

Ces approches combinent des méthodes de caractérisation et tentent de créer des "caractéristiques visuelles" facilement manipulables par les utilisateurs et correspondent parfaitement à nos objectifs initiaux. Il nous semble donc pertinent d'aller plus loin dans ce sens afin d'essayer de combler certaines lacunes des propositions passées. Dans [Tamura *et al.*, 1978, Amadasun et King, 1989], les auteurs démontrent la correspondance de leurs caractéristiques avec le système visuel humain mais ne comparent pas la performance de leurs descripteurs à d'autres attributs de textures. De plus, la plupart de ces propositions ne prennent pas en considération la multirésolution. Enfin, le dernier aspect primordial réside dans la proposition de modes d'exploitation concrets de ces combinaisons de caractéristiques visuelles dans le cadre d'applications réelles. En effet, il s'agit de démontrer que l'utilisabilité annoncée de ces caractéristiques est effective pour les utilisateurs.

## 1.3 Caractérisation des textures solides

Avant toute chose, il est préférable de rappeler que les textures solides, aussi appelées textures volumétriques, sont des textures représentées dans l'espace 3D qui peuvent être considérées comme des séries d'images texturées 2D ou comme un ensemble de voxels situé dans un volume. Celles-ci sont différentes des textures 3D ou des textures volumiques. Les textures 3D [Cuba et Dana, 2004] désignent la texture 2D d'un objet 3D vu d'un angle particulier avec différentes conditions d'éclairage. Les textures volumiques [Neyret, 1995] correspondent au rendu de reflets et géométries répétitives à l'intérieur une image 2D.

Comme nous l'avons vu tout au long de cet état de l'art, beaucoup d'efforts ont été menés pour analyser les textures en 2 dimensions. Cependant, peu de méthodes ont été étendues en vue d'analyser les textures solides. L'analyse des textures est présente dans de nombreux domaines comme l'analyse d'images médicales ou le traitement de

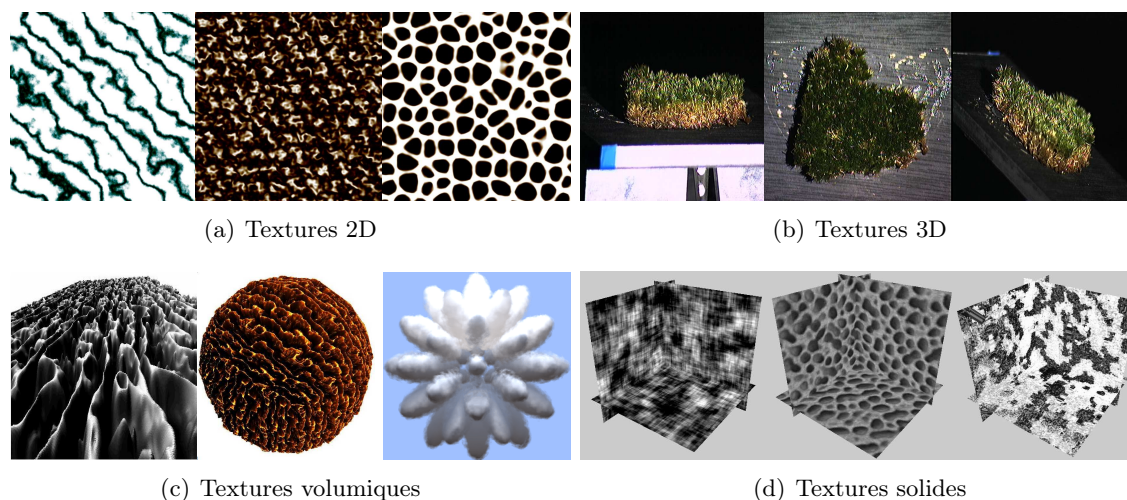


FIG. 1.24 – Illustration sur différents types de représentations des textures

documents. En imagerie médicale, l'analyse des textures est fréquemment utilisée car elle permet de segmenter de façon robuste des images complexes comme par exemple les images ultrasonores. Elle est également très utile pour caractériser un tissu afin d'aider les médecins dans leurs diagnostics. Le progrès des technologies a comme conséquence l'accroissement de l'utilisation d'images 3D, notamment en imagerie médicale avec les images à résonance magnétique, la radiographie digitale, les images échographiques etc. Ce besoin de traiter des images médicales 3D, a fait que certaines méthodes d'analyses de textures ont été étendues au domaine 3D assez récemment.

La plus simple façon d'étudier une image 3D est d'utiliser l'une des méthodes 2D d'analyse de textures sur chacune des coupes 2D texturée qui la composent. Nous ne parlerons pas ici de ce type de méthodes qui n'exploite aucunement les informations 3D disponibles.

Dans [Suzuki *et al.*, 2004], les auteurs proposent une extension de HLAC (*High order local autocorrelation*) à la troisième dimension. Les données 3D sont analysées à partir de masques HLAC 3D qui sont des cubes divisés en grilles de dimension  $3 \times 3 \times 3$ . Pour tester leur méthode, ils génèrent deux types de textures volumétriques : des textures basées sur des fonctions *Perlin's noise* [Perlin, 1985] et des textures construites à partir de fonctions *Perlin's noise* avec un bruit fractal.

Dans la littérature, beaucoup d'articles proposent d'utiliser une extension 3D des matrices de cooccurrence des niveaux de gris. [IP et Lam, 1994] sont les premiers à utiliser une matrice de cooccurrence avec des données 3D. Les textures solides sont séparées via une structure d'*octree* en plusieurs partitions. Chaque noeud de l'*octree* représente une partition, et les arêtes, les relations de voisinage entre 2 partitions. Pour chacun des noeuds, des caractéristiques d'Haralick 3D sont calculées. Les noeuds ayant des caractéristiques similaires sont fusionnés afin de produire une segmentation. [Kovalev *et al.*, 1999] proposent deux approches pour la caractérisation de textures solides. La première méthode utilise un histogramme des orientations 3D calculé à partir de vecteurs de gradient selon plusieurs orientations. La deuxième méthode est une extension 3D des matrices de cooccurrence de Chetverikov. A partir de ces deux méthodes, ils caractérisent des textures

synthétiques avec différents niveaux de bruit, ainsi que des images médicales en vue de surveiller l'évolution de pathologies. Ces deux approches permettent de caractériser précisément l'anisotropie d'une texture, cependant, pour un problème de classification il faudrait associer ces caractéristiques avec d'autres descripteurs de textures pour avoir des informations supplémentaires.

Dans [Ghoneim *et al.*, 2003], les auteurs proposent une classification de tumeurs dans le cerveau par l'analyse de textures. Pour cela, ils calculent des caractéristiques de textures à partir des matrices de cooccurrence d'Haralick 2D mais aussi 3D. Dans tous les cas, les caractéristiques d'Haralick calculées à partir de la 3D donnent de meilleurs résultats que les matrices de cooccurrence 2D. En utilisant la troisième dimension, l'information concernant la distribution des niveaux de gris est plus riche. De la même façon, [Showalter *et al.*, 2006] utilisent les caractéristiques de textures d'Haralick 3D pour prédire des propriétés de micro-architectures des os.

[Kovalev *et al.*, 2003b] utilisent le module du gradient calculé à partir du filtre de Zucker-Hummel. Les amplitudes calculées leur permettent de construire une matrice de cooccurrence 3D. En interprétant les résultats, les auteurs concluent que toutes les coupes du cerveau ne sont pas nécessaires pour déterminer si un sujet est schizophrène. Dans [Kovalev *et al.*, 2001], les auteurs proposent de construire une matrice de cooccurrence en utilisant les niveaux de gris et le module du gradient. Cette matrice est utilisée pour la discrimination d'ensemble de données sur le cerveau de patients ayant des perturbations cognitives légères. Ils proposent également d'utiliser cette technique pour la segmentation de lésions dans le cerveau.

Pour la classification de motifs de sous-cellule, les auteurs utilisent dans [Chen et Murphy, 2004] une combinaison de deux méthodes de caractérisation de textures volumétriques avec les matrices de cooccurrence d'Haralick 3D et des caractéristiques morphologiques et frontières. Les auteurs concluent en disant que la combinaison de caractéristiques permet d'améliorer les résultats de classification.

Parmi les méthodes utilisées pour analyser les textures solides, nous retrouvons les méthodes fréquentielles avec notamment les filtres de Gabor et les ondelettes discrètes. [Jafari-Khouzani *et al.*, 2004] cherchent à caractériser des hippocampes dans un cerveau à partir d'images 3D à résonance magnétique. Pour cela, ils calculent l'énergie moyenne sur les coefficients d'ondelette obtenus à partir d'une décomposition en ondelette discrète 2D sur chacune des coupes de l'hippocampe. De la même façon, ces caractéristiques sont calculées, mais cette fois-ci en utilisant une décomposition en ondelette 3D sur le volume de l'hippocampe. Leurs résultats montrent que sur ce type d'images, la décomposition en ondelette 2D permet une meilleur séparabilité qu'avec les ondelettes 3D.

[Zhan et Shen, 2006] présentent un modèle déformable et l'appliquent sur des images échographiques 3D. Pour approximer l'ensemble des caractéristiques qu'il est possible d'obtenir avec des filtres de Gabor 3D, ils calculent des caractéristiques en utilisant deux bancs de filtres de Gabor 2D positionnés dans les deux plans orthogonaux. Cette méthode permet d'alléger les temps de calcul par rapport à un filtre 3D, mais elle entraîne une perte d'information non-négligeable. [Bigun, 1994] fait une présentation des filtres de Gabor 3D. [François *et al.*, 2003] les appliquent pour segmenter des images ultrasonores 3D de carotide. En utilisant l'information de textures obtenue à partir des filtres de Gabor 3D, ils définissent une mesure de similarité qui permet de labéliser les différentes zones

de l'image. Dans [Fernandez *et al.*, 2000], les auteurs segmentent des zones sismiques 3D en utilisant des caractéristiques obtenues à partir de filtres de Gabor 3D ainsi qu'à partir d'une décomposition en ondelette par paquet. [Shen et Bai, 2008] proposent de régler les paramètres de l'algorithme SPM (*Statistical Parametric Mapping*) en utilisant l'entropie calculée à partir de la réponse maximale locale d'une ondelette de Gabor 3D. [Aldasoro et Bhalerao, 2007] proposent une méthode de segmentation multirésolution pour la segmentation de textures solides. Pour cela, ils extraient des caractéristiques du domaine de Fourier à partir de sous-bandes [Wilson et Spann, 1988] en utilisant une pyramide d'orientation. Ils proposent également une sélection de caractéristiques à partir de l'espace *Bhattacharya* basée sur une distance *Bhattacharya*. Après avoir construit un *oct tree*, ils proposent d'identifier les différentes classes à une résolution spatiale faible puis de les répercuter à la résolution de l'image d'origine. Ils appliquent cette méthode sur des images à résonance magnétique de genoux humains et obtiennent de bons résultats. Il pourrait être intéressant de voir les performances de cette méthode sur des images médicales plus difficiles à traiter comme par exemple des images échographiques 3D. La conclusion de ce panorama de méthodes d'analyse volumétrique est qu'il s'agit pour l'instant de travaux émergeant. Il est donc nécessaire d'explorer plus profondément le sujet pour produire des méthodes exploitant encore mieux les informations 3D disponibles. Il faut noter qu'aucune expérimentation ou étude n'a été menée jusqu'à présent pour essayer de proposer ou construire une "caractérisation visuelle ou qualificative" dans le cadre de la description de textures solides.

### 1.4 Méthodes d'exploitation des caractéristiques de textures

Dans la section précédente, nous avons décrit une grande partie des méthodes utilisées en analyse de textures. Il nous paraît également important de faire un rapide bilan sur les différents modes d'exploitation possibles des descripteurs obtenus. Deux grandes catégories de problématiques se dégagent : les cadres applicatifs faisant intervenir des problèmes de classification et les problèmes de segmentation d'images.

#### 1.4.1 Méthodes de classification

La classification de textures consiste à associer une classe ou un label, à une texture donnée, en fonction des caractéristiques présentes. Une première étape importante est donc l'extraction des caractéristiques de textures. Ces attributs de textures sont calculés à partir des méthodes que nous avons présentées à la section 1.2. Ces caractéristiques sont regroupées sous forme de vecteurs numériques et sont, par la suite, directement utilisées par un classificateur. Une deuxième étape importante du processus de classification est donc le choix du classificateur. Il est possible d'utiliser soit une approche supervisée, soit une approche non-supervisée.

Dans le cadre de la classification non-supervisée [Qin *et al.*, 2008], il est généralement nécessaire d'indiquer le nombre de classes recherchées. Les textures similaires sont alors regroupées à l'intérieur d'une même classe sans l'intervention de connaissances *a priori* et simplement à partir d'estimations de similarité entre caractéristiques.

Dans le cadre de l'indexation d'images, les approches supervisées [Li *et al.*, 2003] sont

généralement préférées. Parmi elles, nous pouvons citer les  $k$  plus proches voisins [Chitre et Dhawan, 1999], l'analyse discriminante linéaire [Clausi et Jernigan, 2000], la quantification vectorielle supervisée [Randen et Husóy, 1999], les classificateurs Bayésiens [Manian et Vasquez, 1998], les réseaux de neurones [Laine et Fan, 1993] mais aussi les machines à vecteur support [Vapnik, 1995]. L'utilisation des techniques supervisées nécessite une première phase d'apprentissage durant laquelle le système apprend les caractéristiques associées à chaque classe d'une base d'apprentissage. Une fois cette étape réalisée, ces méthodes supervisées sont capables de classifier les individus d'une base de test en fonction des caractéristiques de textures qui leur sont associées. Les applications en classification de textures sont très nombreuses et constituent encore aujourd'hui un pôle de recherche important [Laine et Fan, 1993, Valkealahti et Oja, 1998, Randen et Husóy, 1999, Li et Shawe-Taylor, 2005, Aldasoro et Bhalerao, 2007, Kim et Kang, 2007, Ferri *et al.*, 2008, Guo *et al.*, 2009].

### 1.4.2 Méthodes de segmentation de textures

La segmentation d'une image texturée consiste à diviser cette même image en plusieurs régions homogènes comportant des caractéristiques de textures identiques. Plusieurs approches utilisent des descripteurs de textures afin de segmenter une image. Parmi elles, nous pouvons citer les méthodes basées sur les contours actifs, la ligne de partage des eaux, et les méthodes de type *clustering* de pixels/voxels.

De manière générale, lorsqu'il s'agit de textures, les méthodes de segmentation basées contours sont proscrites puisqu'une texture ne comporte en général pas de frontières franches. Les approches régions sont plus adaptées, mais la faible homogénéité de l'intensité des pixels/voxels, habituellement exploitée par ce type d'approche, doit être remplacée par un mécanisme plus complexe.

La ligne de partage des eaux est utilisée afin de segmenter une image à partir d'une fonction de hauteur classiquement représentée par un gradient des intensités de niveaux de gris. Dans sa version de base, cette méthode n'est pas toujours efficace pour segmenter des régions texturées qui sont perceptuellement homogènes. Afin d'utiliser cette méthode pour la segmentation de textures, il est nécessaire d'établir une fonction de hauteur permettant de prendre en considération les différences entre l'ensemble des textures présentes dans l'image. Dans [Hill *et al.*, 2002, Malpica *et al.*, 2003], les auteurs proposent d'utiliser la notion de gradient de textures qui correspond à une fonction de hauteur construite à partir des vecteurs de caractéristiques sur chaque pixel/voxel.

Concernant les méthodes basées sur les contours actifs, les dernières avancées en recherche se focalisent sur l'intégration de caractéristiques de textures servant à guider le contour. Dans [Savelonas *et al.*, 2008], une méthode de contours actifs, guidée à partir des caractéristiques de textures LBP est proposée. Dans cet article, les auteurs présentent un état de l'art sur l'ensemble des techniques de contours actifs utilisant une information de textures. Ils les regroupent en deux catégories : les méthodes basées sur les ondelettes et les filtres de Gabor, et les méthodes basées sur des mesures statistiques.

Parmi les contours actifs utilisant des méthodes fréquentielles, nous retrouvons la méthode présentée dans [Sandberg *et al.*, 2002], proposant d'utiliser un banc de filtres de Gabor avec le modèle proposé dans [Chan *et al.*, 2002]. Dans [Paragios et Deriche, 1999], les au-

teurs proposent une méthode de segmentation supervisée utilisant un banc de filtres de Gabor permettant de guider le modèle de contour actif géodésique [Caselles *et al.*, 1997]. Il en existe encore un certain nombre utilisant des principes de fonctionnement similaires [He *et al.*, 2004, Liapis *et al.*, 2004, Sagiv *et al.*, 2006, Lecellier, 2009].

Parmi les méthodes basées sur les statistiques, nous pouvons citer [Lehmann *et al.*, 2001, Pujol et Radeva, 2004] qui proposent des méthodes supervisées de segmentation de textures utilisant les caractéristiques d'Haralick. D'autres méthodes, comme celle présentée dans [Rousson *et al.*, 2003], proposent une approche supervisée utilisant à la fois des caractéristiques statistiques et d'orientation.

Les méthodes de *clustering* sont non-supervisées et permettent de classifier et de regrouper les pixels/voxels d'une image ayant des caractéristiques de textures identiques. Contrairement aux méthodes de contours actifs, ces méthodes ne se limitent pas à l'exploration d'une zone de l'image et permettent d'obtenir une segmentation incluant l'ensemble des pixels/voxels d'une image. Parmi ces méthodes de clustering, souvent exploitées en segmentation de textures, nous pouvons citer les K-means [Coleman et Andrews, 1979], CLARA [Kaufman et Rousseeuw, 1990], CLARANS [Ng et Han, 1994] mais également l'algorithme de BIRCH [Zhang *et al.*, 1996].

Les méthodes présentées dans cette sous-section sont celles qui sont le plus classiquement utilisées et permettent la génération d'une segmentation à partir de l'utilisation de vecteurs de caractéristiques de textures ou bien d'un gradient de textures. D'autres méthodes comme les champs de Markov proposent une approche différente et permettent d'obtenir des segmentations à l'aide de métaheuristiques appliquées sur le modèle choisi (voir sous-section 1.2.3.1).

## 1.5 Comparaison de méthodes d'analyse de textures

Dans ce paragraphe, nous passons en revue les comparaisons et les évaluations de méthodes d'analyse de textures fournies par la littérature. Nous avons vu dans le paragraphe précédent que beaucoup d'efforts avaient été menés pour analyser les textures en 2D mais beaucoup moins dans le cadre de la 3D. De façon naturelle, les articles d'évaluation proposent uniquement des comparaisons de méthodes 2D. L'absence de travaux pour l'analyse de performance d'algorithme 3D s'explique sûrement par l'absence de bases de données de textures 3D suffisamment riche pour mettre en place un protocole d'évaluation. La mise en place d'une telle base de donnée constitue l'une de nos contributions que nous détaillons section 3.1.1.

Dans [Stachowiak *et al.*, 2005], les auteurs proposent de comparer six méthodes d'analyse de textures invariantes à la rotation et aux changements d'échelle : les matrices de cooccurrence [Haralick, 1979], les transformées en ondelette discrète, une combinaison des ondelettes et des caractéristiques de cooccurrence [Arivazhagan et Ganesan, 2003], les filtres de Gabor, les champs de Markov aléatoires Gaussiens [Chellappa et Jain, 1993, Cohen et Cooper, 1987, Chellappa et Chatterjee, 1985] et la méthode des motifs binaires (LBP)[Ojala *et al.*, 1996, Ojala *et al.*, 2001, Ojala et Pietikäinen, 2002]. Dans leur étude, ils proposent d'évaluer les différentes méthodes d'analyse de textures à l'aide d'un pro-



blème de classification utilisant quatre ensembles d'images comprenant des textures de Brodatz, des images fractales isotropiques, des images microscopiques (images naturelles) de surfaces sablées et de surfaces érodées. Pour chaque méthode, des résultats de classification sont générés à partir de deux classificateurs : les  $k$  plus proches voisins, et le classificateur en analyse discriminante linéaire. Leur étude montre que les filtres de Gabor et les champs de Markov aléatoires gaussiens donnent de bons résultats sur les textures de Brodatz. Pour les autres images, les résultats sont pauvres et peu satisfaisants. La méthode LBP/VAR affiche de très bonnes performances pour les textures de Brodatz et les images de type sablées. Cependant, le nombre d'erreurs de classification augmente lorsque la taille de l'image analysée diminue. L'erreur de classification est également élevée pour les images de type érodées et les images fractales. Les matrices de cooccurrence sont efficaces sur les images de type sablées mais leur performance est faible sur des images anisotropiques comme les surfaces érodées. La transformée en ondelette discrète donne de mauvais résultats sur les images fractales, par contre, sa performance sur les images de type sablées et de type érodées est très satisfaisante. Enfin, la combinaison entre la transformée en ondelette discrète et les caractéristiques de cooccurrence donne de bons résultats dans l'ensemble des cas ce qui nous conforte dans notre idée de mieux exploiter la combinaison de méthodes de caractérisation.

Dans [Sharma et Singh, 2001], les auteurs étudient 5 méthodes d'analyse de textures à travers un problème de classification en utilisant la base de donnée *Meastex*. Parmi elles, nous retrouvons : les matrices de cooccurrence des niveaux de gris, la fonction d'auto-corrélation, les filtres de Laws [Laws, 1980b], des détecteurs de frontières pour la description de textures, ainsi que des primitives de taille [Sharma et Singh, 2001]. Dans leur analyse, les auteurs utilisent une analyse discriminante linéaire mais aussi deux algorithmes modifiés des  $k$  plus proches voisins. Parmi toutes ces méthodes, les matrices de cooccurrence et la méthode de Laws donnent les meilleurs taux de reconnaissance. Les auteurs concluent en affirmant que les différentes méthodes d'analyse de textures permettent d'obtenir différents aspects des textures et qu'il pourrait être intéressant de les combiner.

[Unser, 1995] compare, à l'aide d'un problème de classification, les frames d'ondelette (DWF) avec la décomposition en ondelette discrète classique (DWT). Pour cela, 12 textures de la base de données de Brodatz et de dimension  $256^2$  pixels sont utilisées. Pour chaque texture, un total de 64 vecteurs de caractéristiques indépendantes est évalué (série de sous-régions non-superposées et de taille  $32^2$  pixels). Par la suite, les textures sont classifiées à l'aide d'un classificateur bayésien. Dans tous les cas, la DWF donne de meilleurs résultats que la DWT. En effet, l'approche DWF réduit la variabilité concernant les caractéristiques de textures, ce qui améliore les performances de classification. Il souligne également l'importance de la multirésolution pour obtenir une discrimination efficace des textures. Pour lui, les approches traditionnelles (matrices de cooccurrence [Haralick, 1979], les champs de Markov gaussien, etc.) sont restreintes à une analyse très locale, ce qui en fait des méthodes performantes pour l'analyse de micro-textures. Au contraire, les méthodes fréquentielles comme les filtres de Gabor ou les ondelettes permettent d'avoir des informations sur la texture qui sont à la fois locales et globales, ce qui permet une caractérisation de meilleure qualité.

[Ojala *et al.*, 1996] étudient, grâce à un test de classification, quatre techniques d'analyse de textures avec les matrices des différences de niveaux de gris GLDM [Unser, 1986] (*Grey*

*Level Difference matrices*(GLDM)), les mesures de covariance symétriques centrées (*center-symmetric covariance measures*(CSCM)), les filtres de Laws (*Laws texture method*(LTM)) et le descripteur LBP(*Local Binary Pattern*). Dans leur expérimentation, les textures à reconnaître sont obtenues en sous-échantillonnant aléatoirement les images texturées d'origine provenant de l'album de Brodatz. Les résultats de classification sont générés à partir d'une méthode basée sur la discrimination de Kullback. GLDM donne dans l'ensemble de très bons résultats. De plus, cette méthode n'est pas très coûteuse en temps de calcul. De la même manière, LBP offre de très bonnes performances pour une faible complexité. Cependant, cette méthode n'est pas robuste au changement d'intensité. Pour résoudre ce problème, Ojala fait une combinaison des caractéristiques LBP avec une simple mesure de contraste qui permet d'améliorer de façon considérable les performances de caractérisation. Enfin LTM et CSCM donnent de moins bons résultats et nécessitent des échantillons d'images plus importants que les méthodes LBP et GLDM.

De nombreuses études comparent les caractéristiques obtenues à partir de filtres et celles obtenues à partir de matrices de cooccurrence des niveaux de gris pour la classification de textures. Dans [Strand et Taxt, 1994], les auteurs concluent que les matrices de cooccurrence des niveaux de gris donnent de meilleurs résultats. Au contraire, les auteurs dans [Laws, 1980a, Pietikäinen *et al.*, 1983, Clausi et Jernigan, 1996] concluent que les méthodes avec filtres sont plus performantes.

[Chen et Chen, 1999] comparent, dans un problème de classification de textures, plusieurs méthodes de type fréquentiel avec la transformée de Fourier, le filtre spatial, les filtres de Gabor et la décomposition en ondelette discrète sur des images naturelles de la base de Brodatz et sur des images synthétiques obtenues à l'aide de champs de Markov. Lorsque le nombre de caractéristiques est restreint (4 caractéristiques), les filtres Gabor sont les plus performants. Cependant avec plus de caractéristiques (12 caractéristiques), les ondelettes calculées sur trois niveaux de décompositions donnent les meilleurs résultats avec très peu d'erreur de classification.

[Pichler *et al.*, 1996] comparent les ondelettes et les filtres de Gabor et ils concluent que les filtres de Gabor sont plus performants mais aux dépens d'un effort de réglage conséquent. Dans [Chang et Kuo, 1993], l'auteur affirme que les ondelettes sont plus naturelles et efficaces pour des textures avec une dominance de fréquences moyennes alors que les filtres de Gabor sont plus appropriés pour des images composées de basses fréquences.

## 1.6 Modélisation d'un système de reconnaissance de textures

Dans cette section, nous essayons d'identifier à travers une modélisation, les différents facteurs étant susceptibles d'intervenir dans un système de reconnaissance de textures. Pour caractériser une texture, le cheminement utilisé est très souvent le suivant : un ensemble de caractéristiques, généralement numériques, assimilables ou non par l'humain et en nombre plus ou moins important, sont calculées à partir d'une méthode d'analyse de textures. Une deuxième étape, facultative, consiste à sélectionner les caractéristiques les plus pertinentes dans l'ensemble initial. En lien avec cette étape, les différentes caractéristiques peuvent être combinées (linéairement ou non) afin de créer de nouveaux attributs de textures.

## 1.6. MODÉLISATION D'UN SYSTÈME DE RECONNAISSANCE DE TEXTURES

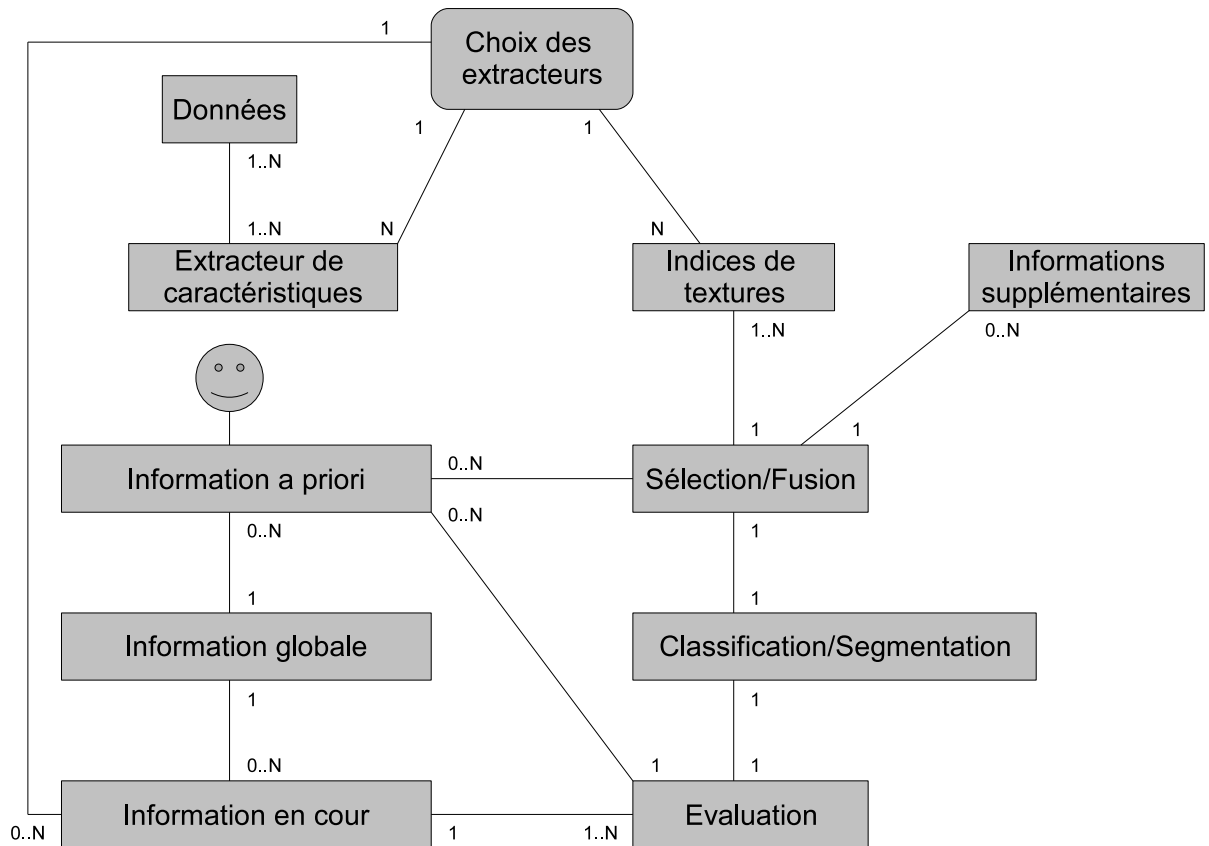


FIG. 1.25 – Système de reconnaissance de textures

Dans cette modélisation, nous faisons apparaître des notions supplémentaires avec en premier lieu ce que nous appelons les « caractéristiques supplémentaires ». En utilisant des informations dites non-texture, un système peut être capable de reconnaître une texture. Par exemple, l'être humain est capable d'utiliser des informations de forme (d'un objet) pour en déduire plus facilement des informations sur sa texture : l'objet identifié est un arbre donc la texture à reconnaître est de type « Bois ». Les « informations *a priori* » sont des connaissances apportées avant l'exécution du système et peuvent être fournies de différentes manières. L'utilisateur du système peut par exemple choisir de ne retenir qu'un certain nombre d'indices de textures car il juge qu'ils seront suffisants et nécessaires pour une bonne reconnaissance. Les « informations en cours » sont des informations amenées à mûrir au fur et à mesure de l'évolution du système. Dans cette modélisation, elles peuvent intervenir dans le choix des extracteurs de caractéristiques en se basant sur le résultat des différentes évaluations. En effet, il est possible d'utiliser plusieurs extracteurs pour obtenir une même caractéristique et le but est alors de ne retenir que les plus performants. Cette information peut également être utilisée pour sélectionner les indices de textures les plus pertinents. Enfin les « informations globales » font office de mémoire du système. Leur rôle est alors d'influencer le système dans le cas d'une situation déjà rencontrée ou très similaire.

Formellement, nous considérons  $D$  les données à traiter (images texturées) qui sont définies selon une dimension mais aussi selon leur espace de représentation (spatial ou fréquentiel). Nous définissons également  $A$  comme l'ensemble possible des extracteurs de textures sachant que chacun d'eux permet d'obtenir un ou plusieurs attributs de textures  $T$ . Nous pouvons alors écrire :

$$a_{i,j} \in A \text{ avec } i \in \{1..N\} \text{ et } j \in \{1..M_i\}$$

avec  $a_{i,j}$  l'extracteur  $j$  permettant d'obtenir la caractéristique  $i$ ,  $N$  le nombre de caractéristiques possibles et  $M_i$  le nombre d'extracteurs permettant d'obtenir la caractéristique  $i$ . Un indice de textures  $T_i$  s'exprime alors de la façon suivante :

$$a_{i,j} : D \rightarrow T_i$$

Un indice  $T_i$  est dépendant de la résolution mais aussi de la régionalité (voisinage) considérée.

Un ensemble de caractéristiques  $F = \{T_1, T_2, \dots\}$  est alors calculé à partir des données  $D$ , de l'ensemble des extracteurs  $A$  et des informations en cours  $K_{ec}$ .

$$Cei : D \times A \times K_{ec} \rightarrow F$$

avec  $Cei$  la fonction de choix des indices et des extracteurs.

Une sélection de caractéristiques peut alors être effectuée à la fois sur  $F$  l'ensemble des caractéristiques utilisées mais aussi sur  $O$  qui représente ce que nous appelons les caractéristiques supplémentaires :

$$Select : F \times O \times K_{ap} \rightarrow F'$$

$Select$  est la fonction de sélection,  $K_{ap}$  représente les informations *a priori* et  $F' \subseteq F$ .

Par la suite une fonction de classification ou segmentation  $ClassSeg$  est appliquée sur ces données :

$$ClassSeg : K_{ap} \times F' \rightarrow R$$

$R$  représentant un résultat sous forme de labels ou de frontières selon la problématique.

Enfin une fonction d'évaluation  $Eval$  permet de vérifier la pertinence des résultats. Selon le type d'évaluation (évaluation supervisée ou non-supervisée) une connaissance *a priori* intervient dans le système.

$$Eval : K_{ap} \times R \rightarrow L$$

avec  $L$  un indice ou un ensemble d'indices de qualités.

Cette modélisation met en avant toutes les difficultés qu'il est possible de rencontrer dans un système de reconnaissance de textures. En effet, il est nécessaire de traiter plusieurs problématiques telles que le choix ou le calcul des caractéristiques de textures, le choix des méthodes de classification ou de segmentation, la mise en place de méthodes d'intelligence artificielle permettant d'exploiter les informations du connexes etc. Dans cette thèse, nous nous focaliserons sur le choix des caractéristiques à exploiter avec une attention particulière sur l'interaction Homme-Machine. Beaucoup d'extracteurs de textures proposent des caractéristiques difficilement compréhensibles par un être humain ce qui rend impossible leur exploitation dans un cadre applicatif concret. Les propriétés que nous recherchons impliquent de définir une texture à partir d'attributs visuels correspondant à des adjectifs qualificatifs non ambigus du langage naturel.

## 1.7 Conclusion

L'analyse des textures est extrêmement répandue pour le traitement d'images 2D et s'étend actuellement à la 3D. Nous avons présenté dans cet état de l'art une grande panoplie des méthodes permettant de caractériser les textures afin de traiter des problèmes de classification et de segmentation d'images texturées. Cette étude nous a permis de mettre en évidence plusieurs points cruciaux concernant l'analyse de textures 2D et volumétriques, soulignant notamment les avantages et inconvénients de chaque approche. Les points fondamentaux que nous avons mentionnés sont la régionalité, la multirésolution, la facilité de manipulation, la sélection et combinaison de caractéristiques et leur adaptation aux textures solides.

Dans une problématique de segmentation, le choix du voisinage (régionalité) est primordial et dépendant du type de textures traitées. La régionalité doit être suffisamment large pour contenir l'ensemble ou une grande partie des motifs de base de la texture considérée. Dans [Jan et Hsueh, 1998], les auteurs proposent de prédire la taille de la fenêtre de voisinage sur des textures structurées (déterministes, observables). Pour cela, ils utilisent les propriétés de périodicité de ce type de textures. Cependant, cette problématique reste encore d'actualité et il serait intéressant de mettre en place des méthodes efficaces quel que soit le type de textures traité.

Comme mentionné par les auteurs dans [Randen et Husøy, 1999], il est difficile d'affirmer qu'une méthode d'analyse de textures est clairement la plus performante. Sur l'ensemble des articles faisant des comparatifs de méthodes d'analyse de textures, certains aboutissent à des conclusions contradictoires. Chaque évaluation est faite à partir de bases de données et de critères différents, ce qui peut expliquer la divergence de certains résultats. Si nous faisons une synthèse sur l'ensemble des comparaisons proposées dans la littérature, il en ressort tout de même une préférence pour les méthodes fréquentielles [Pietikäinen *et al.*, 1983, Unser, 1995, Clausi et Jernigan, 1996, Randen et Husøy, 1999, Reyes-Aldasoro, 2004, Stachowiak *et al.*, 2005]. De façon générale, ces méthodes décrivent une texture localement et globalement, ce qui permet une caractérisation plus complète. En effet, ces approches intègrent la notion de multi-résolution ce qui permet de caractériser une texture selon plusieurs échelles d'observation. Tout comme la régionalité, la résolution est un paramètre important et il n'est pas toujours évident de savoir quel sont les résolutions qu'il est nécessaire d'explorer. Il est également important de souligner les bonnes performances que procure la combinaison de plusieurs descripteurs de textures [Ojala *et al.*, 1996, Sharma et Singh, 2001, Stachowiak *et al.*, 2005]. Chaque méthode d'analyse permet de décrire différents aspects dans une texture et des combinaisons pertinentes peuvent aboutir à des descriptions très précises. De ce point de vue, la majeure partie des méthodes d'analyse de textures n'ont pas d'applicabilité générale et dans certains cas ne sont pas capables d'identifier certaines classes de textures. En comparaison, le système visuel humain est efficace sur tous types de textures même en l'absence d'un contexte favorable. De façon générale, les êtres humains utilisent des propriétés texturales comme la directionnalité, la rugosité, le contraste, la granularité, etc. Afin d'avoir des mesures générales sur les textures, certains auteurs [Tamura *et al.*, 1978, Amadasun et King, 1989] ont présenté des recherches dans cette direction en proposant des descripteurs de textures 2D compréhensibles par des êtres humains.

Parmi les méthodes statistiques les plus utilisées, nous retrouvons les matrices de cooccurrence des niveaux de gris d'Haralick (GLCM). Celles-ci sont facilement extensibles à la 3D cependant leur complexité de calcul n'est pas négligeable. Certaines des caractéristiques d'Haralick extraites à partir de ces matrices sont compréhensibles et quantifiables par un être humain (contraste). Pour d'autres, il est plus difficile de produire une interprétation visuelle (somme des entropies).

Les méthodes d'analyse de motifs s'attachent à déterminer et étudier les structures et les motifs composant une texture. Les méthodes comme les graphes de Voronoï permettent d'analyser géométriquement une texture en construisant un maillage à partir des informations de niveaux de gris. Celles-ci sont basées sur la construction de graphes, ce qui rend possible leur extension en 3D. D'autres méthodes, également utilisables sur des images 3D, proposent d'identifier les textures d'une texture à partir de bancs de filtres. La méthode LBP est une technique efficace avec une complexité très faible. Cependant, l'extension 3D de celle-ci n'est pas forcément aisée car dans le domaine 3D le nombre de motifs qu'il est possible de générer devient très important. Pour caractériser une texture, cette méthode recense dans un histogramme 1D l'ensemble des motifs binaires identifiés à l'intérieur de celle-ci. Il n'y a donc aucune correspondance entre cette façon de décrire une texture et celle utilisée par les êtres humains. Pour la plupart, ces méthodes diffèrent des mécanismes de qualification utilisés par les êtres humains. Il faut noter cependant quelques exceptions [Mital *et al.*, 1994, Goyal *et al.*, 1994a, Goyal *et al.*, 1994b, Goyal *et al.*, 1995, Shoshany, 2008] où les auteurs proposent de calculer des informations de compacité et de forme sur des motifs binaires. Ces descripteurs de textures se révèlent tout à fait exploitables et compréhensibles pour un utilisateur non expert en analyse d'image.

Parmi les méthodes basées sur un modèle, nous avons présenté les champs de Markov ainsi que les fractales. Les champs de Markov permettent de décrire une texture à partir du voisinage décrit par un ensemble de cliques selon un type de connexité choisi. En considérant un voisinage 3D, ces méthodes sont donc naturellement extensibles au domaine 3D. Il faut cependant noter que ces méthodes sont gourmandes en temps de calcul. Enfin, il est difficile de mettre en correspondance les paramètres d'un modèle Markovien, utilisés pour caractériser les textures, avec la description humaine des textures. La dimension fractale permet d'avoir une bonne estimation de la rugosité d'une texture. Celle-ci est une caractéristique facilement quantifiable par un être humain. De plus, certaines méthodes d'estimation de la dimension fractale, comme la méthode du *Box counting* sont facilement applicables aux textures solides. Avec les fractales, il est possible de calculer d'autres types de caractéristiques pour améliorer leur performance. Cependant, utilisés seuls, ces descripteurs restent peu efficaces.

Parmi les méthodes empruntées au traitement du signal, les plus populaires pour le traitement des textures sont les ondelettes discrètes et les filtres de Gabor. L'une comme l'autre, ces méthodes sont extensibles à la 3D. Si la décomposition en ondelette 3D d'une texture solide est rapide, il n'en est rien concernant son analyse avec un filtre de Gabor 3D. Ces derniers permettent une analyse très précise mais le nombre important de paramètres peut entraîner des calculs lourds. Les caractéristiques de ce type de méthodes sont calculées directement sur les réponses de filtres générés. Même si ces caractéristiques sont de type statistique, il est bien souvent impossible d'en déduire une correspondance avec le processus de description humain.

## 1.7. CONCLUSION

---

Dans la suite, nous nous attacherons à proposer de nouveaux descripteurs de textures permettant de caractériser de façon robuste et générique les textures volumétriques. Cet ensemble d'attributs sera le résultat de la combinaison de méthodes d'extraction de différents types (fréquentielle, géométrique, statistique). De plus, les caractéristiques choisies devront correspondre à des concepts facilement exploitables et manipulables par des utilisateurs non experts en vision par ordinateur. Le prochain chapitre présente les différents attributs de textures choisis ainsi qu'une description détaillée des méthodes développées pour les obtenir.

## 1.7. CONCLUSION

---



## Chapitre 2

# Caractérisation visuelle de textures volumétriques

### 2.1 Proposition de caractéristiques de textures compréhensibles par un être humain

Dans le chapitre 1, nous avons constaté que la plupart des méthodes d'analyse de textures se focalisent sur les images 2D et qu'elles ne permettent pas d'identifier toutes les classes de textures possibles. De plus, elles sont la plupart du temps difficilement appréhendables par l'être humain et donc difficilement utilisables dans la pratique. En conclusion, nous avons noté l'intérêt de combiner plusieurs méthodes de caractérisation de textures en s'inspirant du système visuel humain. C'est la raison pour laquelle nous nous focalisons, dans cette thèse, sur la proposition de caractéristiques de textures, adaptées aux images 3D, construites avec l'aide de méthodes réputées comme performantes, et correspondant à des adjectifs fréquemment utilisés par les humains pour décrire des textures. L'objectif secondaire est ensuite de faire en sorte que l'ensemble des descripteurs proposés soit suffisamment complet afin d'obtenir un système facilement adaptable pour pouvoir traiter différents types de textures sans introduire trop de redondances et de complexités. Pour répondre à toutes ces exigences, nous avons choisi, à l'aide de travaux antérieurs décrits dans le chapitre précédent [Tamura *et al.*, 1978, Amadasun et King, 1989], d'exploiter les caractéristiques suivantes : la rugosité, la granularité, le contraste, la directionnalité, la régularité, mais également des informations de formes comprenant la compacité et le volume des motifs. Certaines de ces caractéristiques se calculent à partir d'informations globales sur la répartition spatiale des niveaux de gris (rugosité), alors que d'autres demandent une analyse locale des éléments de base (motifs) d'une texture (granularité, information de forme). Toutes correspondent à des adjectifs communément utilisés par les êtres humains pour décrire des textures, ce qui facilitera leur manipulation et interprétation, lors de la mise en place et configuration d'applications réelles. Encore faut-il qu'il n'y ait pas d'ambiguïté sur la définition associée à chacun de ces attributs. Voici donc les définitions que nous avons retenues :

**Definition 2.1.1.** *La rugosité* : Une texture rugueuse est une surface ou un volume qui

## 2.1. PROPOSITION DE CARACTÉRISTIQUES DE TEXTURES COMPRÉHENSIBLES PAR UN ÊTRE HUMAIN

---

*présente des aspérités (surface inégale, raboteuse au toucher). D'un point de vue psycho-visuel, une texture rugueuse présente des changements d'intensités rapides ainsi que des irrégularités. La notion de rugosité s'oppose à la notion d'homogénéité qui est caractéristique de plages uniformes.*

Dans la littérature, un certain nombre de méthodes permettant de calculer la rugosité ont été proposées. Dans la partie état de l'art, nous en avons détaillé un certain nombre avec notamment la dimension fractale [Medioni et Yasumoto, 1984], la transformée de Fourier [Tsai et Tseng, 1999], mais aussi des méthodes de type statistique [Luk et Huynh, 1987, Tamura *et al.*, 1978, Amadasun et King, 1989, Al-Kindi *et al.*, 1992, Zhongxiang *et al.*, 2008].

**Definition 2.1.2. *Le contraste*** : *Il peut être défini comme le rapport entre les parties les plus foncées et les parties les plus claires d'une image. Mesurer le contraste revient à évaluer la dispersion des niveaux de gris d'une image. Selon [Tamura et al., 1978], quatre facteurs influencent le contraste :*

- *La variation des niveaux de gris*
- *Le pourcentage des zones noires et des zones blanches*
- *L'acuité des frontières*
- *La période de répétition des motifs*

Cette caractéristique est souvent calculée en étudiant de façon statistique la répartition des intensités de niveau de gris [Haralick *et al.*, 1973, Unser, 1986, Tamura *et al.*, 1978, Amadasun et King, 1989, Guo *et al.*, 2009]

**Definition 2.1.3. *La granularité*** : *Qualité ou propriété de ce qui est granulaire. Une surface granulaire se compose de petits éléments. Par analogie, une texture granulaire est une texture composée de petits motifs. Celle-ci peut donc être associée à la mesure du nombre de motifs élémentaires composant une texture. La granularité donne des informations sur la finesse d'une texture.*

Parmi les méthodes qui en proposent une estimation, nous retrouvons la fonction d'autocorrélation [Gagalowicz, 1983], les méthodes fractales avec la caractéristique de lacunarité [Myint et Lam, 2005] ainsi que les méthodes basées sur l'étude de composantes connexes [Shoshany, 2008].

**Definition 2.1.4. *La régularité*** : *Elle permet de mesurer le caractère répétitif d'une texture. Par exemple une texture dite déterministe aura une forte régularité de par la répétition d'un même motif facilement identifiable.*

La régularité d'une texture peut être mesurée en étudiant la répartition et l'évolution de ses intensités mais aussi en étudiant la variation des motifs de base qui la composent. Un certain nombre de méthodes peuvent être utilisées avec la fonction d'autocorrélation [Lin *et al.*, 1997], les matrices de cooccurrence [Selkäinaho *et al.*, 1988], les matrices de cooccurrence binaires [Starovoitov *et al.*, 1998].

**Definition 2.1.5. *La compacité*** : *Cette mesure décrit la géométrie des motifs d'une texture permettant de déterminer s'ils ont une forme plutôt compacte ou une forme plutôt allongée.*

## 2.1. PROPOSITION DE CARACTÉRISTIQUES DE TEXTURES COMPRÉHENSIBLES PAR UN ÊTRE HUMAIN

---

Une étude géométrique des motifs d'une texture permet une bonne approximation de la compacité. Nous avons vu dans la partie état de l'art qu'un certain nombre d'auteurs proposent de la calculer à travers l'étude de composantes connexes [Mital *et al.*, 1994, Goyal *et al.*, 1994a, Goyal *et al.*, 1994b, Goyal *et al.*, 1995].

**Definition 2.1.6. *Le volume*** : *Ce descripteur mesure l'espace 2D ou 3D occupé par les motifs d'une texture solide.*

Tout comme la compacité, la caractérisation du volume des motifs se fait bien souvent à travers l'étude géométrique de motifs binaires [Mital *et al.*, 1994, Goyal *et al.*, 1994a, Goyal *et al.*, 1994b, Goyal *et al.*, 1995].

**Definition 2.1.7. *La directionnalité*** : *Cette information traduit la forte ou faible présence d'une direction privilégiée, produite par les motifs d'une texture.*

De nombreuses méthodes permettent de mesurer l'anisotropie d'une texture. Parmi elles, nous pouvons citer les statistiques d'ordre 2 [Haralick *et al.*, 1973, Chetverikov, 1995, Tamura *et al.*, 1978], la transformée de Radon [Radon, 1917, Guedon *et al.*, 1995], les études sur les gradients d'intensité [Coquerez et Phillip, 1995], la rose des directions [Coster et Chermand, 1989], la transformée en ondelette [Aydin *et al.*, 1996], la transformée de Hough [Duda et Hart, 1972].

A travers ces définitions, nous mettons en avant les propriétés que nous considérons comme fondamentales et que nous choisissons d'extraire pour caractériser une texture. Dans la figure 2.1, nous présentons des images présentant des valeurs extrêmes pour chacun des attributs de textures que nous proposons. Avant d'expliquer la manière de quantifier ces caractéristiques pour les images 3D, il semble opportun de discuter certains points, qui suite à cette proposition, peuvent poser question.

### 1. **Les descripteurs proposés sont-ils les plus pertinents ? Sont-ils suffisamment complémentaires et non redondants ?**

Pour établir cette liste de descripteurs de textures, nous nous sommes attaché à choisir des adjectifs qualificatifs utilisés fréquemment par l'homme pour décrire des textures. Ces adjectifs permettent d'avoir une certaine richesse de description des textures ainsi qu'une caractérisation générique. Certains auteurs ont déjà travaillé sur cette problématique [Tamura *et al.*, 1978, Amadasun et King, 1989] et leurs travaux ont conforté le choix de certaines de nos caractéristiques. En ce qui concerne la redondance et la complémentarité de nos descripteurs de textures, nous présentons dans la section 2.5.1, un ensemble de tests de corrélation.

### 2. **Dans la partie état de l'art, nous avons souligné l'importance de la façon d'observer une texture, qu'il s'agisse de l'échelle d'observation (résolution) ou de la région d'observation considérée (régionalisé).**

Les caractéristiques permettant de décrire une texture sont directement dépendantes de la résolution à laquelle la texture est observée. Ainsi, nous avons indiqué à plusieurs reprises l'importance d'utiliser une approche multirésolution lorsque l'on désire obtenir un système robuste et générique. L'approche que nous proposons respecte donc cette contrainte et intègre un schéma d'analyse multirésolution (Figure 2.2). Pour

## 2.1. PROPOSITION DE CARACTÉRISTIQUES DE TEXTURES COMPRÉHENSIBLES PAR UN ÊTRE HUMAIN

---

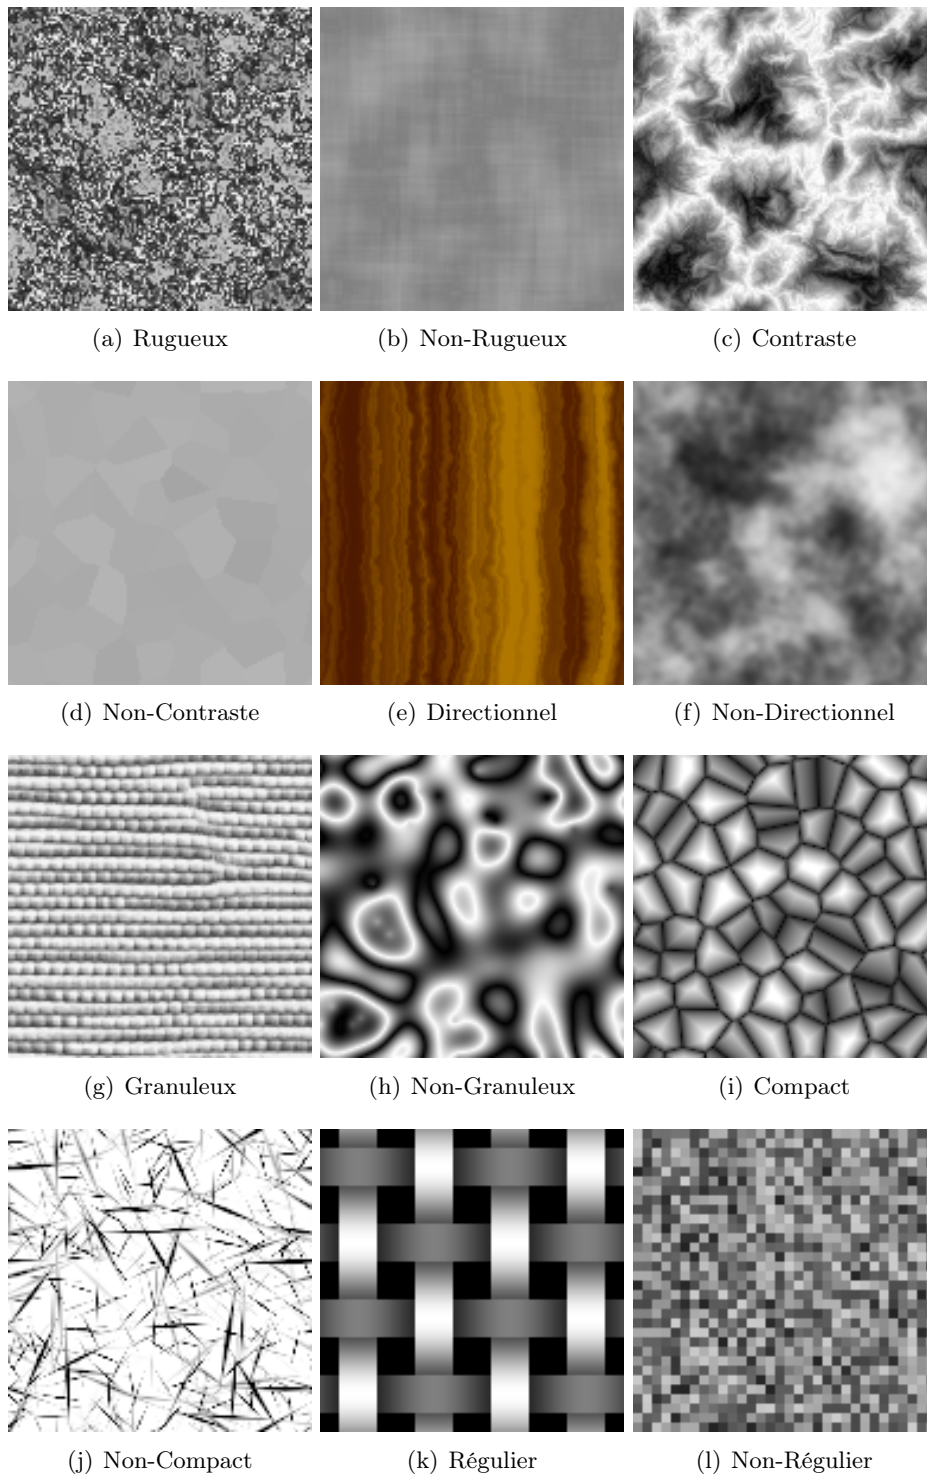


FIG. 2.1 – Représentation d’images extrêmes pour chacune des caractéristiques proposées.


cela, nous utilisons une décomposition en ondelette discrète 3D similaire à celle proposée dans [Mallat, 1989]. Mallat propose un schéma de décomposition à partir de filtres : un filtre passe-haut permettant d'obtenir les coefficients de détails et un filtre passe-bas pour obtenir les coefficients d'approximation. Chacune des caractéristiques proposées sera calculée à plusieurs résolutions. A chaque niveau de décomposition, les valeurs obtenues peuvent être concaténées, ou combinées (linéairement) pour constituer le vecteur soumis au classificateur. Par ailleurs, la rugosité et la directionnalité sont calculées à partir des coefficients de détails alors que les autres caractéristiques proposées le sont à partir de l'image initiale et de ses approximations successives.

Comme dans la majorité des méthodes d'analyse d'images, nous définissons dans notre approche une régionalité autour d'un voxel à l'aide d'un cube de dimension  $N^3$ . Nous avons constaté que certains auteurs avaient proposé des méthodes, applicables sur des textures structurées, pour déterminer automatiquement un voisinage optimal [Jan et Hsueh, 1998]. Dans notre système, ce paramètre n'est actuellement pas déterminé automatiquement mais défini par l'utilisateur. Proposer une méthode qui soit efficace sur tout type de textures reste un objectif ambitieux en dehors des objectifs que nous nous sommes fixés pour cette thèse. Il faut noter cependant que la multirésolution permet de relaxer ce problème puisqu'un voisinage d'observation est défini pour chaque résolution. Il est donc probable d'avoir une régionalité pertinente au moins à une résolution donnée, pour traiter correctement des problèmes d'analyse de textures.

## 2.2 Caractérisation géométrique des textures

La caractérisation locale des textures est généralement réalisée par l'extraction et l'analyse de la forme, la taille et la répétitivité des motifs de base appelés "textons". Différentes techniques sont utilisables pour cela, notamment la méthode des polygones de Voronoi [Tuceryan et Jain, 1990] qui permet de caractériser une texture à travers la distribution spatiale locale des germes qui constituent les différents polygones de Voronoi. D'autres méthodes proposent d'étudier les motifs binaires d'une texture. Parmi elles nous trouvons des méthodes d'analyse de la compacité [Mital *et al.*, 1994, Goyal *et al.*, 1994a, Goyal *et al.*, 1994b, Goyal *et al.*, 1995] mais également la méthode de Shoshany qui propose de décomposer une image de niveau de gris en une succession de textures binaires [Shoshany, 2008].

Après avoir adapté certaines de ces techniques aux images 3D pour évaluer leur efficacité et leur généralité, nous avons choisi d'étudier l'aspect géométrique des textures par la caractérisation des composantes connexes obtenues après binarisation (figure 2.3). En effet, pour calculer les composantes connexes (les motifs) d'une image, il est nécessaire au préalable de la binariser. Cette phase de binarisation constitue une étape stratégique lorsqu'il s'agit d'analyser les formes d'une image texturée. Ainsi, dans la sous-section 2.2.2, plusieurs méthodes d'extraction de composantes connexes sont proposées afin d'obtenir des caractéristiques qui soient stables et les plus représentatives possible des textures à étudier. Par la suite, nous définissons de façon formelle le terme de composante connexe. Soit  $A$



CD : Coefficients de détail

CA : Coefficients d'approximation

FIG. 2.2 – Schéma représentatif du calcul des caractéristiques proposées

et  $B$  deux points d'un sous-ensemble  $S$  de l'image  $I$ .  $A$  et  $B$  sont dits connectés dans  $S$ , si et seulement si, il existe un chemin connexe dans  $S$  reliant  $A$  et  $B$ . La relation "être connecté" dans  $S$  est une relation d'équivalence. Les composantes connexes de l'image sont égales aux *classes d'équivalence* de cette relation [Rosenfeld, 1970].

Calculer les composantes connexes d'une image binaire correspond à l'association d'une même étiquette pour chacune des régions qui la compose. Pour cela, il existe plusieurs algorithmes, dont les principaux sont expliqués par [Chassery et Montanvert, 1991]. Parmi ces méthodes nous avons choisi d'adapter à la 3D un algorithme ne nécessitant que deux passages sur les pixels d'une image afin d'extraire les composantes connexes (algorithme 1 et 2). Ainsi la complexité dépend uniquement de la taille de l'image alors que dans un algorithme purement séquentiel, le nombre d'itérations dépend de la complexité des objets. En contrepartie, cette méthode requiert l'utilisation d'une table de correspondance entre étiquettes que nous appelons  $T$  [Rosenfeld et Pfaltz, 1966].

---

**Algorithme 1** : Calcul des composantes connexes (1er balayage de l'image)

---

**Données** : T un tableau de correspondance des étiquettes

```

1 début Initialisation
2   | T[i] :=i
3 fin
4 début
5   pour tous les points P de l'image faire
6     // Un point objet est un voxel qui est comptabilisé comme
7     // appartenant à une composante connexe
8     si les prédécesseurs points objets de P ont une même étiquette alors
9       | Attribuer cette étiquette à P;
10    sinon
11      // Attribution à P de la plus petite étiquette e non nulle de
12      // ses prédécesseurs
13      P :=T[e];
14      // Mise à jour de la table T
15      pour chaque prédécesseur d'étiquette a tel que T[a]≠T[e] faire
16        tant que T[a]≠a faire
17          | k :=T[a];
18          | T[a] :=T[e];
19          | a :=k;
20          T[a] :=T[e];
21      // Actualisation de la table T pour que chaque indice correspondant
22      // à l'étiquette définitive de l'objet
23      pour i allant de 1 au nombre d'étiquettes utilisées faire
24        | j :=i;
25        tant que T[j]≠j faire
26          | j :=T[j];
27        T[i] :=j;
28 fin

```

---




FIG. 2.3 – Ce schéma présente de gauche à droite : une image ultrasonore 3D en niveau de gris, une version binaire de cette même image, et deux représentations 3D de composantes connexes, extraites à partir de deux images binarisées à des seuils différents.

---

**Algorithme 2** : Calcul des composantes connexes (balayage retour de l'image)

---

```

1 début
  // Le deuxième balayage de l'image permet d'associer une étiquette
  // unique à chacune des composantes connexes.
2 pour chaque point objet P d'étiquette e faire
3   si T[e] ≠ e alors
4     P := T[e];
5 fin

```

---

### 2.2.1 Caractéristiques obtenues par étude des composantes connexes 3D

Les composantes connexes d'une texture binaire représentent la géométrie des objets de base qui la compose. Leur analyse permet de fournir des informations sur le volume et la structure des motifs. Grâce à leur étude, il est possible d'obtenir des connaissances sur la granularité, correspondant au nombre de motifs par unité de volume, ainsi que sur la compacité et le volume de chaque composante connexe, ce qui permet d'avoir des informations de forme sur les éléments d'une texture. Il est également possible d'estimer la régularité des motifs à partir de leur variance. Dans notre cas, le nombre de motifs d'une texture correspond au nombre de composantes connexes ( $nbCC$ ) par unité de volume. Pour une texture donnée, la granularité ( $f_{gran_\beta}$ ) est significative si le nombre de composantes connexes à une résolution  $\beta$  est important. Elle est calculée de la façon suivante :

$$f_{gran_\beta}(x, y, z) = \frac{nbCC_\beta}{N^3} \quad (2.1)$$

Les composantes connexes considérées sont localisées dans un cube de taille  $N^3$  centrées aux coordonnées  $(x, y, z)$ .  $N^3$  représente donc le volume du voisinage considéré (régionalité). De plus, nous proposons de calculer des caractéristiques de formes avec le volume moyen et la compacité moyenne des composantes connexes. Tout comme la granularité, le volume



donne des informations sur la finesse d'une texture. Le volume moyen des composantes connexes est calculé de la façon suivante :

$$f_{vol_\beta}(x, y, z) = \left( \sum_{i=1}^{nbCC_\beta} V_{i,\beta} \right) / nbCC_\beta \quad (2.2)$$

avec  $V_{i,\beta}$  le volume de la composante connexe  $i$  à la résolution  $\beta$ .

La compacité est une caractéristique permettant de décrire la forme des motifs d'une texture. Une texture avec une compacité importante se compose de motifs avec une forme compacte. Dans le cas contraire, les motifs sont filiformes et allongés. Cette caractéristique est invariante à tous types de transformations comme la translation, la rotation mais également les changements d'échelle [Zhang et Tan, 2002]. Dans la littérature, il est possible de trouver plusieurs méthodes d'analyse de textures utilisant cette caractéristique [Mital *et al.*, 1994, Goyal *et al.*, 1994a, Goyal *et al.*, 1994b, Goyal *et al.*, 1995]. La compacité d'une composante connexe se définit de la façon suivante :

$$C_{i,\beta} = \frac{S_{i,\beta}^{\frac{3}{2}}}{V_{i,\beta}} \quad (2.3)$$

avec  $S_{i,\beta}$  la surface et  $V_{i,\beta}$  le volume de la composante connexe  $i$  à la résolution  $\beta$ .

Nous pouvons alors calculer la compacité moyenne  $f_{comp_\beta}$  :

$$f_{comp_\beta}(x, y, z) = \frac{1}{nbCC_\beta} \sum_{i=1}^{nbCC_\beta} C_{i,\beta} \quad (2.4)$$

Il est également possible d'obtenir des informations sur la régularité d'une texture en étudiant la variation de forme de ses composantes connexes. Pour cela nous avons choisi de calculer la variance sur les caractéristiques de compacités de l'ensemble des motifs. Nous avons vu que la compacité était invariante à tout type de transformations [Zhang et Tan, 2002]. Ainsi, la variance sur les motifs d'une texture est uniquement affectée par leur forme. Si une texture présente une forte régularité, alors la variance de la compacité des composantes connexes est faible, et ceci quel que soit l'agencement spatial des motifs. On obtient :

$$f_{reg_\beta}(x, y, z) = E(C_\beta^2) - (E(C_\beta))^2 \quad (2.5)$$

avec  $E$  la fonction d'espérance.

### 2.2.2 Méthodes de génération de composantes connexes 3D

Pour calculer les composantes connexes d'une image, il est nécessaire d'effectuer une binarisation au préalable. Dans cette sous-section, nous proposons de tester plusieurs méthodes de génération de composantes connexes. Pour cela, différents cas de figure sont envisagés : une première méthode utilisant la binarisation de Niblack [Niblack, 1986] (approche locale), une méthode utilisant une binarisation globale, et enfin une méthode utilisant un

## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES

---

	Zone d'intérêt 1	Zone d'intérêt 2	Zone d'intérêt 3	Zone d'intérêt 4
$f_{gran}$	17	11	9	10
$f_{comp}$	34.4	52.6	80.2	61.1
$f_{reg}$	3726.3	3822.6	24206.9	4296.8
$f_{vol}$	976.5	1441.9	1863	1569.9

TAB. 2.1 – Tableau de caractéristiques calculées à partir d'une binarisation Niblack

ensemble d'images binaires, obtenues à partir de seuils différents. Cette dernière permet de conserver l'information sur la dynamique des niveaux de gris constituant une texture. Pour choisir la méthode la plus pertinente, la stabilité et la représentativité des textures sont analysées pour chacune d'entre elles.

### 2.2.2.1 Binarisation par l'algorithme de Niblack

Le principe de la méthode de Niblack est de calculer un seuil de binarisation pour chaque pixel de l'image d'origine en utilisant la moyenne et l'écart type des niveaux de gris. Le seuil  $S$  au voxel de coordonnées  $(x, y, z)$  est calculé de la façon suivante :

$$S(x, y, z) = m(x, y, z) + k.e(x, y, z) \quad (2.6)$$

avec  $m(x, y, z)$  et  $e(x, y, z)$  la moyenne et l'écart type dans un voisinage local aux points de coordonnées  $(x, y, z)$ .

Cette méthode nécessite le réglage de deux paramètres : la largeur de la fenêtre de voisinage ainsi que le paramètre  $k$ . La taille du voisinage doit être suffisamment petite pour prendre en compte le niveau d'illumination local et suffisamment grande pour inclure à la fois les objets et le fond. Dans [Trier et Taxt, 1995], les auteurs conseillent d'utiliser un voisinage de largeur  $15^2$  et de prendre la valeur  $k = -0.2$  pour binariser des images de documents.

La figure 2.4 représente une texture binarisée par l'algorithme de Niblack avec un voisinage de  $15^3$  et  $k = -0.2$ . Sur cette texture nous calculons les caractéristiques obtenues à partir des composantes connexes sur plusieurs zones d'intérêts définies par le cube violet. Celles-ci sont présentées dans la table 2.1. Nous pouvons remarquer que selon les zones d'intérêt choisies, la variation des différentes caractéristiques n'est pas négligeable. Par exemple la zone d'intérêt 1 comprend 17 composantes connexes avec un volume moyen de 976.5, alors que la zone d'intérêt 3 contient 9 composantes connexes avec un volume moyen de 1863. La binarisation de Niblack est une binarisation locale, cependant elle n'empêche pas la génération de composantes parasite (bruit ou composantes à négliger) qui perturbent les caractéristiques obtenues. A travers différents tests, nous avons pu constater que le nombre de composantes parasites était encore plus important pour des voisinages faibles. Il paraît donc logique de prendre des voisinages assez grands. Cependant, cette condition engendre des temps de calcul très importants. De la même façon, plus la taille du voisinage augmente et plus cette technique tend à se rapprocher d'une binarisation globale remettant ainsi en cause l'utilité d'une méthode locale de binarisation.




FIG. 2.4 – Calcul de caractéristiques (tableau 2.1) sur différentes zones d'intérêts après binarisation avec la méthode de Niblack

### 2.2.2.2 Binarisation globale

Comme précédemment, nous appliquons une binarisation globale sur une texture volumétrique et nous sélectionnons plusieurs zones d'intérêt afin de calculer les caractéristiques basées sur les composantes connexes extraites (figure 2.5). Ici, le seuil de binarisation est fixé par l'utilisateur de façon à obtenir une image binaire qui soit la plus propre possible. Dans le tableau 2.2, nous présentons les caractéristiques obtenues selon les zones d'intérêts sélectionnées. Tout comme avec la méthode de Niblack, nous observons des variations assez importantes dans certains cas. Les caractéristiques sur les zones d'intérêts [2 – 4] sont très similaires mais celles correspondant à la zone d'intérêt 1 diffèrent significativement avec notamment des valeurs de volume et de compacité divisées par deux par rapport aux trois autres. A l'intérieur de la zone d'intérêt 1, nous retrouvons la présence de deux composantes connexes : la première représente la structure principale de la texture alors que la deuxième est une composante parasite, qui, de par sa petite taille, diminue considérablement les valeurs de compacité et de volume. Un autre problème de la binarisation globale reste le réglage du seuil de binarisation. En effet, selon le seuil choisi, les caractéristiques calculées sur les composantes connexes peuvent donner des résultats qui ne sont pas stables (bruit). Également, dans un problème de segmentation, une image est composée de plusieurs textures et il est alors difficile de trouver un seuil qui convient pour chacune d'entre

## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES

	Zone d'intérêt 1	Zone d'intérêt 2	Zone d'intérêt 3	Zone d'intérêt 4
$f_{gran}$	2	1	3	4
$f_{comp}$	294.6	580.8	614	597.9
$f_{reg}$	86607.2	0	75411.1	107255
$f_{vol}$	8954.5	18462	18648	19760

TAB. 2.2 – Tableau de caractéristiques calculées après binarisation globale

elles. Notons cependant que ce seuil peut parfois constituer une connaissance *a priori* et selon la façon dont il est réglé, permettre de faciliter la segmentation d'une zone de l'image. Enfin, dans le cadre d'une classification, il est difficilement envisageable de régler un seuil pour chaque image à classer.

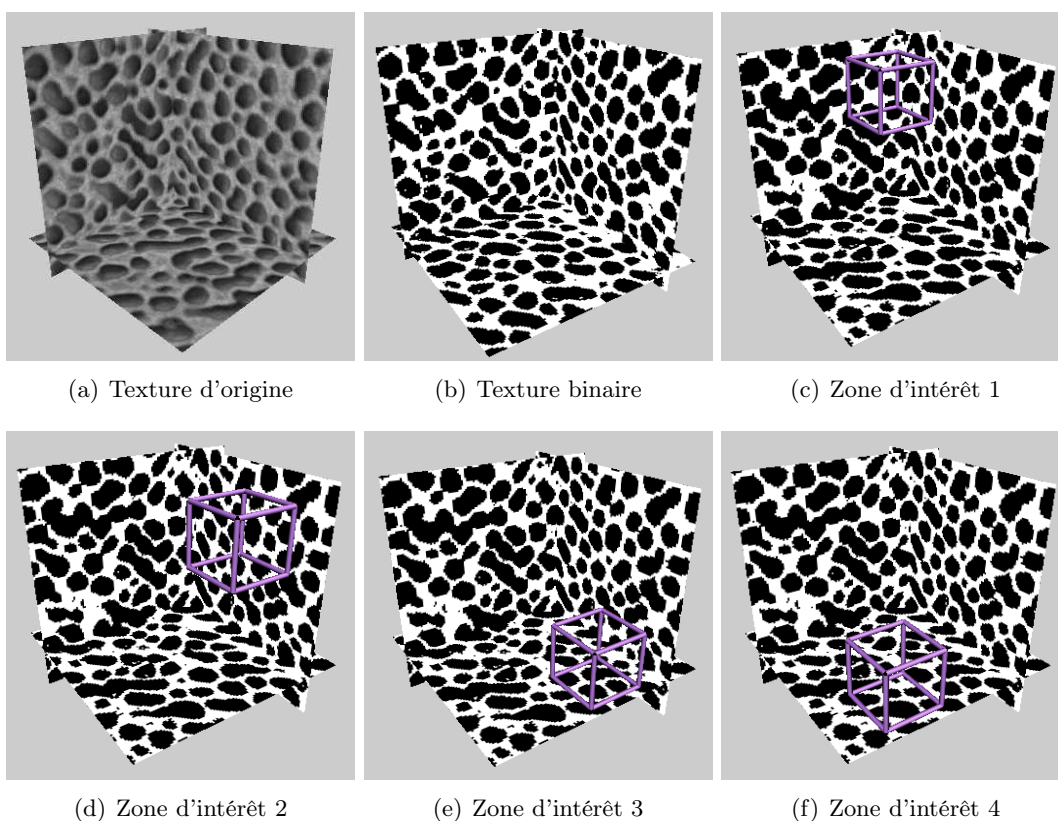


FIG. 2.5 – Calcul de caractéristiques (tableau 2.2) sur différentes zones d'intérêts après une binarisation globale

### 2.2.2.3 Utilisation d'une succession d'images binaires

Le principe de cette méthode consiste à décomposer une texture en niveaux de gris en une succession d'images binaires obtenues en faisant évoluer un seuil de façon progressive. Les composantes connexes et les caractéristiques (nombre de composantes connexes, vo-

## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES

---

lume, compacité et variance de la compacité) sont alors calculées pour chacune des images binaires produites. Nous obtenons donc un jeu de quatre caractéristiques pour chacune des images binaires.

Formellement, nous considérons une image en niveaux de gris  $I_\beta$  à la résolution  $\beta$  et  $B_{i,\beta}$  un ensemble d'images binaires, calculées selon l'algorithme 3, avec  $i = \{1..Q_\beta\}$ . Chaque image binaire  $B_{i,\beta}$  comprend un ensemble de composantes connexes  $CC_{i,\beta} = \{CC_{i,1,\beta}, \dots, CC_{i,n_i,\beta}\}$  avec  $n_{i,\beta}$  le nombre de composantes connexes présent dans  $B_{i,\beta}$ . L'ensemble des composantes connexes  $CC_\beta$  calculé à la résolution  $\beta$ , toutes images binaires confondues, s'écrit alors :

$$CC_\beta = \{\{CC_{1,1,\beta}, \dots, CC_{1,n_1,\beta}\}, \dots, \{CC_{Q_\beta,1,\beta}, \dots, CC_{Q_\beta,n_{Q_\beta,\beta},\beta}\}\}$$

A chaque ensemble  $CC_{i,\beta}$  correspond un ensemble de quatre caractéristiques  $EF_{i,\beta} = \{f_{gran_{i,\beta}}, f_{comp_{i,\beta}}, f_{reg_{i,\beta}}, f_{vol_{i,\beta}}\}$  d'où  $EF_\beta$  :

$$EF_\beta = \{\{f_{gran_{1,\beta}}, f_{comp_{1,\beta}}, f_{reg_{1,\beta}}, f_{vol_{1,\beta}}\}, \dots, \{f_{gran_{Q_\beta,\beta}}, f_{comp_{Q_\beta,\beta}}, f_{reg_{Q_\beta,\beta}}, f_{vol_{Q_\beta,\beta}}\}\}$$

Pour caractériser une texture, nous disposons d'un ensemble de quatre caractéristiques en faisant la moyenne des indices de textures obtenus dans chaque image binaire selon les formules suivantes :

la granularité,

$$f_{gran_\beta}(x, y, z) = \frac{1}{Q_\beta} \sum_{i=1}^{Q_\beta} f_{gran_{i,\beta}}(x, y, z) \quad (2.7)$$

la compacité moyenne,

$$f_{comp_\beta}(x, y, z) = \frac{1}{Q_\beta} \sum_{i=1}^{Q_\beta} f_{comp_{i,\beta}}(x, y, z) \quad (2.8)$$

la régularité (variance sur la compacité),

$$f_{reg_\beta}(x, y, z) = \frac{1}{Q_\beta} \sum_{i=1}^{Q_\beta} f_{reg_{i,\beta}}(x, y, z) \quad (2.9)$$

le volume moyen,

$$f_{vol_\beta}(x, y, z) = \frac{1}{Q_\beta} \sum_{i=1}^{Q_\beta} f_{vol_{i,\beta}}(x, y, z) \quad (2.10)$$

Une approche similaire pour la classification de textures en deux dimensions est proposée dans [Shoshany, 2008] (voir section 1.2.1.5 pour plus de détails). Une texture en niveau de gris est décomposée en une succession de textures binaires pour pouvoir en étudier les motifs. Dans notre proposition, nous calculons une séquence d'images binaires en calculant un pas à partir du nombre d'images binaires souhaité (Algorithme 3). Dans son approche, Shoshany définit  $k$  images binaires qui sont calculées en faisant varier le seuil de binarisation de 1 à  $k$ , avec  $k \in \{1, 256\}$ . Cette méthode permet d'obtenir une séquence d'images binaires plus régulière, cependant l'exploration de tous les niveaux ( $k = 256$ ) demande la

---

**Algorithme 3** : Découpage d'une image en niveaux de gris en un ensemble d'images binaires

---

```

1 début
  // Calcul d'un pas d'avancement pour le seuil en utilisant N le
  // nombre d'images binaires souhaité
2 Pas :=255/N;
3 S :=0;
4 pour i allant de 1 à N faire
5   S :=S+Pas;
6   pour chaque voxel de l'image faire
7     si Intensité du voxel < S alors
8       | Intensité du voxel de l'image binaire i := 0;
9     sinon
10    | Intensité du voxel de l'image binaire i := 1;
11 fin

```

---

	Zone d'inté- rêt 1	Zone d'inté- rêt 2	Zone d'inté- rêt 3	Zone d'inté- rêt 4	Zone d'inté- rêt 5
$f_{gran}$	9.75	9.37	9	8.1	8.8
$f_{comp}$	138.2	137.4	126.4	145.9	117.3
$f_{reg}$	17488.9	17519.2	16416.1	19339.3	8854
$f_{vol}$	17074.9	17115.1	17267.3	17695.1	16897

TAB. 2.3 – Tableau de caractéristiques calculées à partir de plusieurs binarisations

génération d'un grand nombre de textures binaires ce qui dans certains cas peut engendrer des temps de calcul élevés. Pour classifier les textures, Shoshany propose d'utiliser trois caractéristiques prouvées comme complémentaires dans [Luo et Savakis, 2001] : le nombre de motifs, l'hétérogénéité des motifs et la dominance. Ces caractéristiques sont calculées sur l'ensemble des composantes des textures binaires c'est à dire à la fois sur les motifs blancs (*foreground*) et les motifs noirs (*background*). Dans notre approche, les caractéristiques ne sont calculées qu'à partir des motifs (composantes connexes) d'une des deux composantes (blanc ou noir). En effet il y a un équilibre des composantes blanches et noires dans une image binaire et calculer des caractéristiques identiques sur chacune d'entre elles entraîne forcément des redondances inutiles.

Suivant le modèle présenté précédemment, nous calculons les caractéristiques obtenues à partir des composantes connexes sur plusieurs zones d'intérêts, afin d'analyser leur comportement (figure 2.6). Les caractéristiques présentées dans le tableau 2.3 sont calculées à partir d'une séquence de 8 images binaires. Si nous comparons avec les méthodes utilisant la binarisation de Niblack et la binarisation globale, nous observons une bien meilleure stabilité sur l'ensemble des caractéristiques. Le fait d'effectuer nos calculs sur une séquence d'images binaires permet une meilleure robustesse aux composantes parasites. Cela permet

## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES

---

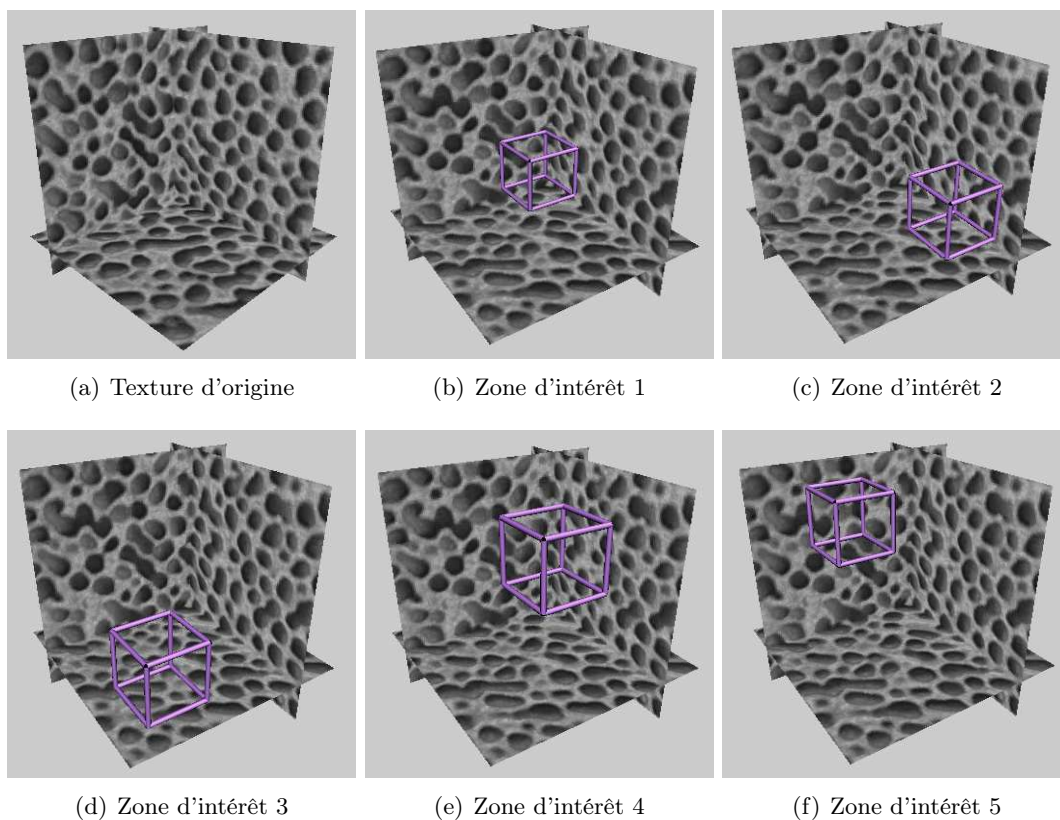


FIG. 2.6 – Zones d'intérêts utilisées pour calculer les caractéristiques de textures présentées tableaux 2.3 et 2.4

également de mesurer la dynamique d'une texture.

Le problème de cette méthode reste le choix du nombre et des seuils de binarisation qui permettent de générer une séquence d'images binaires. Dans la méthode précédente,  $N_\beta$  seuils espacés de façon régulière sont utilisés. Les textures binaires ainsi générées ne permettent pas d'obtenir, dans tous les cas, les informations les plus pertinentes concernant les structures et les motifs de base d'une texture. De plus, certaines textures binaires de la séquence apportent une information redondante voire nulle. Afin d'obtenir des informations qui soient plus appropriées, il serait donc intéressant de sélectionner automatiquement les seuils de binarisation à partir des plages de niveaux de gris les plus représentatives d'une texture. Pour cela, nous proposons d'utiliser un algorithme de regroupement (*clustering* des voxels) afin de créer des classes de niveaux de gris homogènes au sein des images 3D à étudier. La figure 2.7 présente les histogrammes de classes de niveaux de gris de plusieurs textures volumétriques après application de l'algorithme *k-means* selon plusieurs valeurs de  $k$ . Pour chacune des images testées, nous pouvons observer une très forte stabilité des histogrammes obtenus au delà de la valeur  $k = 10$ . Par la suite, la valeur de  $k$  sera donc fixée à 20. Les pics présents dans les différents histogrammes restent identiques quelles que soient les images. Pour récupérer la valeur des pics d'un histogramme (qui serviront

## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES

de seuils par la suite), nous avons choisi de conserver l'ensemble des valeurs de niveaux de gris pour lequel le nombre d'individus dans l'histogramme est supérieur au cumul de la moyenne et la variance du nombre d'individus calculés sur ce même histogramme. La figure 2.7 présente les seuils de binarisation (valeur des pics) ainsi choisis pour chacun des histogrammes.

Parmi les images binaires générées à partir des pics d'histogramme (seuils de binarisation), certaines contiennent beaucoup plus de motifs (composantes connexes) et donc d'informations structurelles locales sur la texture que d'autres. En effet, une image binaire contenant un grand nombre de composantes connexes (motifs binaires) est plus intéressante à analyser géométriquement qu'une image n'en contenant que très peu. Afin de donner plus de poids à ces images binaires, les caractéristiques calculées sur l'ensemble de la séquence d'images binaires, sont pondérées en fonction du nombre de composantes connexes considérées. Nous obtenons finalement les formules de calcul suivantes :

Granularité,

$$f_{gran_\beta}(x, y, z) = \sum_{i=1}^{Q'_\beta} \frac{nbCC_{i,\beta}}{\max_i(nbCC_{i,\beta})} f_{gran_{i,\beta}}(x, y, z) \quad (2.11)$$

Compacité,

$$f_{comp_\beta}(x, y, z) = \sum_{i=1}^{Q'_\beta} \frac{nbCC_{i,\beta}}{\max_i(nbCC_{i,\beta})} f_{comp_{i,\beta}}(x, y, z) \quad (2.12)$$

Régularité,

$$f_{reg_\beta}(x, y, z) = \sum_{i=1}^{Q'_\beta} \frac{nbCC_{i,\beta}}{\max_i(nbCC_{i,\beta})} f_{reg_{i,\beta}}(x, y, z) \quad (2.13)$$

Volume,

$$f_{vol_\beta}(x, y, z) = \sum_{i=1}^{Q'_\beta} \frac{nbCC_{i,\beta}}{\max_i(nbCC_{i,\beta})} f_{vol_{i,\beta}}(x, y, z) \quad (2.14)$$

avec  $Q'_\beta$  le nombre d'images binaires déterminées automatiquement (généralement compris entre 5 et 10),  $nbCC_{i,\beta}$  le nombre de composantes connexes dans l'image binaire  $i$  à la résolution  $\beta$ . Les composantes connexes considérées sont localisées dans un cube de taille  $N^3$  et centré aux coordonnées  $(x, y, z)$ .


	Zone d'intérêt 1	Zone d'intérêt 2	Zone d'intérêt 3	Zone d'intérêt 4	Zone d'intérêt 5
$f_{gran}$	8.09	10.33	9.5	7.98	9.49
$f_{comp}$	24.04	29.11	26.78	25.93	26.21
$f_{reg}$	6491.94	6921.44	7365.9	8418	7117.68
$f_{vol}$	717.38	877.93	794.59	815.74	814.9

TAB. 2.4 – Tableau de caractéristiques calculées sur différentes zones d'intérêts.


Tout comme pour les autres méthodes de binarisation, les caractéristiques géométriques sont calculées sur plusieurs zones d'intérêts (Tableau 2.4). Les résultats présentés montrent



## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES



## 2.2. CARACTÉRISATION GÉOMÉTRIQUE DES TEXTURES



## 2.3. CARACTÉRISATION FRÉQUENTIELLE DES TEXTURES VOLUMÉTRIQUES




FIG. 2.7 – Histogramme du nombre d’individus par classe après application de l’algorithme  $k$ -means sur des textures volumétriques pour différentes valeurs de  $k$ .

une forte stabilité sur l’ensemble des caractéristiques proposées. Sélectionner automatiquement le nombre et les valeurs de seuils de binarisation, et pondérer les caractéristiques pour valoriser les représentations binaires qui sont géométriquement les plus riches, renforce la stabilité de nos caractéristiques. Si nous comparons avec la méthode précédente (succession de  $n$  images binaires) les valeurs de volume et de compacité correspondent encore mieux à la réalité observée. Le volume des motifs est beaucoup moins excessif et les valeurs de compacité indiquent une texture plus compacte par rapport à la méthode précédente. C’est donc cette dernière méthode que nous conservons afin de calculer les caractéristiques de compacité, volume, régularité et compacité.

## 2.3 Caractérisation fréquentielle des textures volumétriques

Mettant de côté les méthodes nécessitant des *a priori* afin de garantir une plus grande généralité et utilisabilité de nos caractéristiques, les méthodes d’analyse fréquentielle se sont imposées pour obtenir des informations à la fois locales et globales sur les textures solides à caractériser. Comme nous l’avons déjà mentionné, [Mallat, 1989] propose un schéma de décomposition en ondelette basé sur l’utilisation de filtres : un filtre passe haut  $g(x)$  permettant d’obtenir les coefficients d’approximations et un filtre passe bas  $h(x)$  permettant d’obtenir les coefficients de détails. En 3D, 8 images sont générées pour un niveau de décomposition : une image pour les coefficients d’approximations et sept pour les coefficients de détails. Les coefficients de détails permettent d’obtenir une description des hautes fréquences d’une image dans une direction donnée.

## 2.3. CARACTÉRISATION FRÉQUENTIELLE DES TEXTURES VOLUMÉTRIQUES

---

Après le processus de décomposition, nous obtenons un ensemble de sous-bandes à partir duquel il est possible de calculer des caractéristiques manipulables par l'utilisateur. Les coefficients d'ondelettes présents dans chaque sous-bande ne sont pas réutilisés directement de par la présence d'une forte variance. Généralement, beaucoup de chercheurs [Unser, 1995, Arivazhagan et Ganesan, 2003, Li et Shawe-Taylor, 2005, Muneeswaran *et al.*, 2005] proposent d'utiliser des statistiques d'ordre 1 comme par exemple la moyenne, la variance, l'énergie, l'entropie, le contraste, etc. Parmi elles, l'une des plus utilisées est l'énergie. Celle-ci peut se calculer sur des images 3D via la formule suivante :

$$E(x, y, z) = \sum_{i=1}^N \sum_{j=1}^N \sum_{k=1}^N |c(i, j, k)| \quad (2.15)$$

avec  $c(i, j, k)$  l'ensemble des coefficients d'ondelettes compris dans un cube de taille  $N^3$  correspondant au voxel d'une sous-bande aux points de coordonnées  $(x, y, z)$ .

### 2.3.1 Estimation de la rugosité

Nous avons choisi d'utiliser cette transformée en ondelette discrète pour caractériser la rugosité d'une texture. Nous avons vu que la rugosité dans une image était synonyme de transitions spatiales rapides avec des amplitudes plus ou moins importantes. D'un point de vue fréquentiel, les aspérités d'une image dans le domaine spatial se traduisent par la présence de hautes fréquences. Pour estimer la rugosité d'une texture, nous nous intéressons uniquement aux coefficients de détails. Nous avons vu que chaque sous-bande de coefficients de détails permet de mettre en évidence les hautes fréquences d'une texture dans une direction particulière. Pour caractériser la rugosité d'une texture à une résolution donnée, nous proposons de calculer l'attribut de textures suivant :

$$f_{rug_\beta}(x, y, z) = \sum_{\alpha=1}^M \left( \sum_{i=1}^N \sum_{j=1}^N \sum_{k=1}^N |w_{\alpha,\beta}(i, j, k)| \right) / M \quad (2.16)$$

avec  $f_{rug_\beta}$  la rugosité à la résolution  $\beta$ ,  $w_{\alpha,\beta}(i, j, k)$  l'ensemble des coefficients de détails compris dans un cube de taille  $N^3$  centré au voxel d'une sous-bande  $\alpha$  aux coordonnées  $(x, y, z)$  et  $M$  le nombre de sous-bandes coefficients de détails pour une résolution.

### 2.3.2 Caractérisation de l'orientation

Dans nos travaux, nous nous intéressons au degré d'orientation d'une texture. Cela revient à déterminer si une texture est plutôt isotrope ou anisotrope.

Nous bénéficions d'une décomposition en ondelette discrète permettant d'avoir une description des textures sur plusieurs résolutions. A partir des coefficients de détails obtenus de la décomposition en ondelette, il est possible d'avoir des informations sur les directions privilégiées dans l'image. En 2D, les 3 sous-bandes coefficient de détails mettent en évidence 3 directions privilégiées, et ceci à chaque résolution (une par sous-bande) : diagonale, horizontale et verticale. En 3D, les 7 sous-bandes permettent d'obtenir des informations

sur 7 directions différentes. Afin d'estimer la force de la direction principale d'une texture, nous proposons de calculer la caractéristique suivante :

$$f_{dir_\beta}(x, y, z) = \max_{\alpha} \left( \sum_{i=1}^N \sum_{j=1}^N \sum_{k=1}^N |w_{\alpha,\beta}(i, j, k)| \right) - \sum_{\alpha=1}^M \left( \sum_{i=1}^N \sum_{j=1}^N \sum_{k=1}^N |w_{\alpha,\beta}(i, j, k)| \right) / M \quad (2.17)$$

avec  $f_{dir_\beta}$  la directionnalité à la résolution  $\beta$ ,  $w_{\alpha,\beta}(i, j, k)$  l'ensemble des coefficients de détails compris dans un cube de taille  $N^3$  centré au voxel d'une sous-bande  $\alpha$  aux coordonnées  $(x, y, z)$  et  $M$  le nombre de sous-bandes coefficients de détails pour une résolution.

## 2.4 Mesure statistique pour le contraste

[Haralick, 1979, Haralick *et al.*, 1973] proposent une mesure pour estimer le contraste en utilisant les statistiques d'ordre 2. Pour cela, le moment d'inertie est calculé à partir de la diagonale principale de la matrice de cooccurrence. Cependant, la construction d'une matrice de cooccurrence permettant d'obtenir une estimation du contraste peut se révéler coûteuse en temps de calcul. Dans [Tamura *et al.*, 1978], les auteurs affirment que quatre facteurs sont supposés influencer les différences de contraste entre deux textures : la gamme dynamique des niveaux de gris, la polarisation de la distribution de noir et de blanc dans l'histogramme des niveaux de gris, l'acuité des frontières et la période de répétition des motifs. Dans leur article, ils proposent une approximation du contraste à l'aide d'une mesure incluant les deux premiers facteurs. C'est cette mesure que nous avons choisi d'utiliser. Pour obtenir une mesure de la polarisation, ils utilisent le kurtosis  $\alpha_4$  qui mesure la disposition des masses de probabilité autour de leur centre.

$$\alpha_{4,\beta} = \frac{\mu_{4,\beta}}{\sigma_\beta^4} \quad (2.18)$$

avec  $\mu_{4,\beta}$  le moment centré d'ordre 4 et  $\sigma_\beta^2$  la variance à la résolution  $\beta$ .

Pour prendre en considération la gamme dynamique des niveaux de gris, ils combinent le kurtosis avec l'écart type de la façon suivante :

$$f_{con_\beta}(x, y, z) = \frac{\sigma_\beta}{\alpha_{4,\beta}^n} \quad (2.19)$$

avec  $n$  valeur positive.

Dans leur article, Tamura *et al* présentent un ensemble de comparaisons entre des expérimentations psychologiques et leurs opérateurs. Ils concluent que la valeur  $n = 1/4$  donne la meilleure approximation. Enfin, les valeurs de  $\sigma_\beta$  et  $\alpha_{4,\beta}^n$  sont calculées dans un cube de dimension  $N^3$  centré aux coordonnées  $(x, y, z)$ .

## 2.5 Expérimentations psychologiques

La section précédente décrit l'ensemble des caractéristiques visuelles que nous avons sélectionné et les méthodes de construction que nous proposons pour les quantifier. L'objectif

## 2.5. EXPÉRIMENTATIONS PSYCHOLOGIQUES

---




FIG. 2.8 – Ensemble des textures solides utilisées dans nos expérimentations psychologiques

des expérimentations présentées dans cette section consiste à montrer la forte correspondance entre les caractéristiques proposées et une qualification humaine des textures. Pour cela, nous proposons de construire un ensemble de prototypes psychométriques et de comparer les résultats fournis par des sujets humains avec ceux renvoyés par nos méthodes de mesure sur les textures.

Dans nos expérimentations, nous utilisons les textures solides présentées à la figure 2.8. Pour construire ces textures, nous avons utilisé les méthodes présentées dans [Kopf *et al.*, 2007, Paulhac *et al.*, 2009] excepté pour les textures (j) et (l) qui sont des sous-ensembles d’images ultrasonores 3D. Chacune d’elles correspond à une texture volumétrique (texture représentée dans le domaine 3D) de taille  $128^3$  avec 256 niveaux de gris. Elles ont été imprimées à partir d’une imprimante HP Color LaserJet 3700 et présentées à des sujets humains. Critère de la base de Riesz.

Le groupe de sujets humains ayant participé à notre expérimentation se compose de 15 hommes et 11 femmes. La majorité d’entre eux n’ont aucune connaissance en traitement d’image et analyse de textures. Nous leur avons distribué un questionnaire (voir annexe D) contenant un ensemble de textures (Figure 2.8) ainsi qu’une explication des caractéristiques de textures utilisées dans notre modèle. Pour chaque caractéristique, nous demandons aux volontaires de classer les textures dans un ordre décroissant, c’est à dire de la plus rugueuse à la plus lisse, de la plus régulière à la plus irrégulière, etc. Grâce à l’ensemble des résultats des questionnaires, nous avons construit un classement de ces textures pour chacun des attributs de textures présentés. Pour une caractéristique donnée, un score est assigné à une texture en fonction de son rang. Par exemple, la texture la plus rugueuse prend la valeur +12 (pour la caractéristique de rugosité), la deuxième +11, la dernière +1 et ceci sur chacun des questionnaires. L’addition des scores de l’ensemble des questionnaires pour chaque texture permet d’obtenir un classement final pour une caractéristique de textures donnée.

En utilisant nos méthodes de calcul de caractéristiques, nous avons également généré un classement des images pour chacun des attributs de textures. Pour cela, un vecteur de sept caractéristiques est calculé pour chaque texture solide du questionnaire. Le tableau 2.5 montre la correspondance entre le classement humain et nos caractéristiques à la première résolution. Le tableau 2.7 présente la corrélation entre le classement humain et les attributs de notre méthode à la deuxième résolution.

### 2.5.1 Comparaison du classement humain et du classement obtenu à partir de nos méthodes de calcul

Afin de comparer le classement obtenu avec nos méthodes de calcul et celui résultant de notre groupe de sujets humains, nous proposons de déterminer le degré de correspondance existant. Pour cela, nous avons choisi d’utiliser le coefficient de corrélation de Spearman qui est calculé de la façon suivante :

$$r_s = 1 - \frac{6}{n^3 - n} \sum_{i=1}^n d_i^2 \quad (2.20)$$

avec  $n$  le nombre d’individus, et  $d_i$  la différence entre les rangs assignés au  $i^{\text{ème}}$  objet dans les deux mesures. Les valeurs de ce coefficient sont comprises entre  $-1$  et  $1$ . La valeur  $1$

## 2.5. EXPÉRIMENTATIONS PSYCHOLOGIQUES

correspond à un parfait accord des deux classements et la valeur  $-1$  à un classement inversé. La table 2.5 présente les coefficients de corrélation de Spearman entre le classement obtenu avec nos méthodes de calcul et le classement humain.

$f_{gran}$	$f_{comp}$	$f_{vol}$	$f_{reg}$	$f_{rug}$	$f_{cont}$	$f_{dir}$
0,83	0,9	0,61	0,82	0,75	0,65	0,7

TAB. 2.5 – Degré de correspondance des caractéristiques de textures à partir des différents classements humains et ceux obtenus à partir de nos méthodes de calculs pour la résolution 1

$f_{gran}$	$f_{comp}$	$f_{vol}$	$f_{reg}$	$f_{rug}$	$f_{cont}$	$f_{dir}$
0,73	0,66	0,42	0,61	0,71	0,45	0,6

TAB. 2.6 – Degré de correspondance des caractéristiques de textures à partir des différents classements humains et ceux obtenus à partir de nos méthodes de calculs pour la résolution 2

Les résultats présentés dans le tableau 2.5 montrent une forte corrélation entre le classement obtenu via les sujets humains et celui obtenu à partir de nos méthodes de calcul. Concernant le volume  $f_{vol}$  le coefficient de Spearman indique qu'il y a un lien entre les deux mesures avec un taux de confiance compris entre 95% et 98%. La caractéristique de compacité donne la meilleure correspondance avec un taux de confiance qui tend vers 100%. Sur l'ensemble des caractéristiques, le volume donne le résultat de corrélation le plus faible. Nous pouvons supposer qu'il est difficile pour un sujet humain de visualiser, d'imaginer le volume des motifs à cause de la troisième dimension.

Dans le tableau 2.6, les correspondances entre le classement humain et le classement informatique sont moins élevées mais restent tout de même assez importantes. Ce phénomène est compréhensible car nous pouvons considérer que les sujets humains ont observé le questionnaire de façon relativement fine renvoyant davantage à la résolution 1 de notre système.

	$f_{rug}$	$f_{comp}$	$f_{vol}$	$f_{reg}$	$f_{cont}$	$f_{dir}$
$f_{gran}$	0,67	0,63	-0,53	0,47	-0,01	-0,02
$f_{dir}$	0,29	0,18	-0,13	0,29	0,34	—
$f_{cont}$	-0,17	-0,25	0,47	-0,23	—	—
$f_{reg}$	0,57	0,59	-0,52	—	—	—
$f_{vol}$	-0,42	-0,45	—	—	—	—
$f_{comp}$	0,59	—	—	—	—	—

TAB. 2.7 – Degré de corrélation obtenu à partir des classements informatiques de chaque caractéristique à la résolution 1

Le tableau 2.7 présente les coefficients de corrélation entre les différentes caractéristiques obtenues à partir de nos méthodes de calcul informatique et le tableau 2.8 correspond aux coefficients de corrélation calculés à partir des classements humains. Grâce à ces résultats, nous pouvons constater qu'il y a une corrélation importante entre les caractéristiques rugosité, compacité et granularité. Nous retrouvons cette correspondance aussi



## 2.6. CONCLUSION

---

	$f_{rug}$	$f_{comp}$	$f_{vol}$	$f_{reg}$	$f_{cont}$	$f_{dir}$
$f_{gran}$	0,73	0,67	-0,39	0,52	0,13	-0,35
$f_{dir}$	-0,17	-0,24	-0,32	0,08	0,42	—
$f_{cont}$	0,28	-0,24	0,12	-0,03	—	—
$f_{reg}$	0,52	0,50	-0,25	—	—	—
$f_{vol}$	-0,55	-0,48	—	—	—	—
$f_{comp}$	0,60	—	—	—	—	—

TAB. 2.8 – Degré de corrélation obtenu à partir des classements humains de chaque caractéristique

bien dans le classement informatique que dans le classement humain. Une texture granuleuse, c'est à dire avec un nombre de motifs important, peut, dans certains cas, présenter un certain nombre d'irrégularités donnant visuellement un aspect rugueux. De la même façon, un regroupement important de motifs donne un aspect plutôt compact. Nous pouvons également constater que la caractéristique de volume est plutôt anti-corrélée si nous la comparons avec les trois précédentes. Concernant la caractéristique de directionnalité, nous pouvons constater qu'elle est très peu corrélée avec l'ensemble des autres caractéristiques. La plus proche est la caractéristique de contraste. Si une texture est anisotrope alors un fort contraste renforcera la valeur du module directionnel. Il faut noter toutefois que les textures choisies dans notre expérience peuvent influencer le fait que certaines caractéristiques de textures soient plus ou moins corrélées (ce qui est vrai dans beaucoup de tests de corrélation). Même s'il existe une corrélation entre certaines caractéristiques, elles ne sont pas pour autant inutiles et peuvent se révéler indispensables dans la discrimination d'un très grand nombre de textures. Il est tout à fait possible de trouver un ensemble de textures granuleuses qui ne soient pas forcément très rugueuses et inversement. A travers ces tests nous espérons faire ressortir ce qui est vrai la plupart du temps dans la réalité.

## 2.6 Conclusion

Dans ce chapitre, nous avons proposé un ensemble de caractéristiques qualificatives de textures dont la définition est compréhensible par un être humain : la granularité, le contraste, le volume, la compacité, la régularité, la directionnalité et la rugosité. Cela permet à un utilisateur du système de sélectionner facilement les caractéristiques susceptibles d'être les plus efficaces pour traiter la problématique envisagée dans le cadre d'une application. Pour que ces caractéristiques soient compréhensibles, nous nous sommes inspiré du vocabulaire employé par les êtres humains lorsqu'ils décrivent des textures. Les méthodes de construction de ces descripteurs tirent parti de l'ensemble des travaux antérieurs produits dans le domaine, ainsi que des nombreuses expérimentations que nous avons menées. Les modes de calcul combinent méthodes fréquentielles d'analyse multirésolution (ondelettes) et méthodes spatiales (composantes connexes multi-niveaux). De cette façon, l'ensemble des caractéristiques proposées garantit une certaine généralité et ne se limite pas au traitement d'une problématique bien spécifique. Les expérimentations psychologiques que nous présentons prouvent la forte correspondance entre les valeurs relatives prises par les des-

## 2.6. CONCLUSION

---

cripteurs proposés et l'appréciation humaine des textures.

Après avoir décrit la base de textures solides que nous avons mis en place, le chapitre suivant présente des tests de classification et de segmentation sur des textures solides afin de valider de façon quantitative notre méthode. Dans le dernier chapitre, des résultats de segmentation sur des images échographiques 3D seront présentés. L'objectif est de démontrer l'efficacité de notre proposition dans le cadre d'applications concrètes diverses (adaptabilité du système).

## Chapitre 3

# Évaluation quantitative des descripteurs qualificatifs proposés

Dans le chapitre précédent, nous avons présenté un ensemble de caractéristiques de textures permettant d'avoir une description qualitative et robuste des textures volumétriques. Dans ce chapitre, nous proposons de tester les caractéristiques de notre méthode HUF (*Human Understandable Feature*) au travers de plusieurs expérimentations visant à produire des résultats quantitatifs. Il sera ainsi possible de comparer objectivement différentes méthodes dans des conditions identiques de travail. Pour cela, nous avons choisi des méthodes d'analyse de textures reconnues dans la littérature : les matrices de cooccurrence d'Haralick qui sont une référence en analyse d'images, ainsi que la méthode des motifs binaires (LBP) reconnue comme très performante et efficace en 2D et que nous avons étendue à la 3D. Cette extension constitue une autre contribution de notre travail décrite dans [Paulhac *et al.*, 2008].

Nous effectuons dans un premier temps des tests de classification, puis dans un deuxième temps, des tests de segmentation sur un ensemble de textures solides de synthèse. Dans les deux cas, les résultats présentés sont des évaluations quantitatives, obtenus à partir de critères d'évaluations reconnus. Afin de réaliser ces expérimentations, et faute de base existante, il nous a d'abord été nécessaire de produire notre propre base de textures solides de synthèse (textures volumétriques). Cette contribution est décrite dans la première partie de ce chapitre.

### 3.1 Base de textures solides pour l'évaluation de méthodes de classification et de segmentation

Dans la littérature, il existe plusieurs types de bases de données concernant le domaine des textures. Parmi les plus connues, nous trouvons les bases de données de textures 2D. La base de données de Brodatz [Brodatz, 1966] mais également la base de Meastex (<http://www.texturesynthesis.com/meastex/meastex.html>) sont souvent utilisées pour leur richesse. Les textures 3D et les textures volumiques, à ne pas confondre avec les textures faisant l'objet de notre étude, sont très différentes des textures so-

### 3.1. BASE DE TEXTURES SOLIDES POUR L'ÉVALUATION DE MÉTHODES DE CLASSIFICATION ET DE SEGMENTATION

---

lides : une texture 3D [Cuba et Dana, 2004] désigne la structure externe observée en 2D, d'un objet 3D vu d'un angle particulier avec différentes conditions d'éclairage; une texture volumique [Neyret, 1995] correspond au rendu de reflets et de géométries répétitifs à l'intérieur d'une image 2D. Parmi les bases de textures 3D, PMTex (<http://www.taurusstudio.net/research/pmtexdb/compare.htm>), CURet (<http://www1.cs.columbia.edu/CAVE/software/curet/index.php>) et OUTex ([http://www.outex.oulu.fi/index.php?page=outex\\_home](http://www.outex.oulu.fi/index.php?page=outex_home)) constituent des références. Concernant les textures volumiques, il est possible d'en trouver un grand nombre sur le site personnel de Neyret (<http://www-evasion.imag.fr/Membres/Fabrice.Neyret/>). Comme nous l'indiquons dans la partie état de l'art, les textures solides (textures volumétriques) sont des textures représentées dans le domaine 3D et sont assimilables à une série d'images texturées 2D ou comme des textures situées dans un espace volumétrique. Dans [Kopf *et al.*, 2007], les auteurs proposent de construire des textures solides à partir d'images de textures 2D. Plusieurs exemples sont disponibles à cette adresse <http://johanneskopf.de/publications/solid/textures/index.html> mais actuellement trop peu d'images sont disponibles pour des expérimentations de classification ou de segmentation.

Dans la partie état de l'art, nous décrivons trois différents types de textures : les textures déterministes, caractérisées par la répétition de motifs identiques; les textures stochastiques, identifiables par leur irrégularité; et les textures observables qui sont un mélange des deux précédentes [Gool *et al.*, 1985].

Afin d'avoir une base de données suffisamment représentative et complète, nous avons choisi de construire des images synthétiques représentatives de ces 3 classes de textures. Pour limiter l'espace disque ainsi que les temps de calcul lors des expérimentations, nous avons construit des textures volumétriques de taille  $64^3$ . Au regard de l'ensemble des tests de classification produits dans la littérature, cette taille semble suffisante et adaptée pour un problème de classification de textures. L'ensemble des images de notre base est construit à partir de quatre méthodes simples que nous détaillons dans les prochaines sous-sections. Pour finir, il est important de préciser que le but de cette base d'images n'est pas de fournir des textures solides qui soient le plus réaliste possible mais plutôt de mettre à disposition un ensemble de classes de textures volumétriques important, afin de permettre l'évaluation d'algorithmes d'analyse de textures solides à travers des tests de classification ou de segmentation.

#### 3.1.1 Méthodes de synthèse utilisées

La première méthode utilisée permet de construire une texture volumétrique en utilisant des images texturées 2D identiques à celles disponibles dans l'album de Brodatz. Deux textures 2D ou plus sont interpolées afin d'obtenir une image 3D (Figure 3.1). Les textures 2D utilisées dans la construction d'une image 3D font partie d'une même classe de textures mais ne sont pas exactement similaires. A partir de cette méthode d'interpolation, les textures volumétriques générées possèdent une direction particulière et évoluent de façon régulière. L'intérieur d'un tronc d'arbre constitue un bon exemple pour illustrer ce type de textures. Formellement, une texture interpolée peut être définie comme un ensemble de

### 3.1. BASE DE TEXTURES SOLIDES POUR L'ÉVALUATION DE MÉTHODES DE CLASSIFICATION ET DE SEGMENTATION

---

blocs texturés  $B_T$  construits à partir de textures 2D  $E_T$  :

$$B_{T,i} = E_T + i \frac{(E_T - E_{T+1})}{M} \quad (3.1)$$

avec  $M = N/(R - 1)$  le nombre de composants 2D dans un bloc,  $N$  la profondeur de la texture solide,  $R$  le nombre d'images texturées 2D utilisées pour l'interpolation,  $T = \{0, \dots, R - 1\}$  et  $i = \{0, 1, \dots, M - 1\}$ .

Les propriétés de ce genre de textures sont dépendantes des textures 2D choisies mais également du nombre de plans d'interpolation.




FIG. 3.1 – Exemple de construction d'une texture solide à partir de la méthode d'interpolation (méthode 1)

La deuxième méthode propose d'utiliser des formes géométriques de base (sphères, cubes, ellipses) incorporées au sein d'une image 3D. Cela permet notamment de construire des textures de type déterministe. Un motif est représenté par une forme géométrique positionnée dans une direction donnée. De plus, il est possible de construire des textures de type observable, par exemple en utilisant des sphères dont la taille et le positionnement sont aléatoires. Il est alors facile de construire une texture de type gryère en insérant aléatoirement des sphères ou des ellipses dont la taille varie. Les propriétés de ce type de textures sont dépendantes du nombre de motifs utilisés, de la forme des motifs, de la taille et de la couleur des motifs, qui peuvent être fixes ou variables. La Figure 3.2 présente deux textures volumétriques générées en utilisant cette méthode.

La troisième méthode mise en place génère des textures volumétriques à partir de la transformée de Fourier [Lewis, 1984]. Pour cela, il est nécessaire de construire un spectre de puissance, qui permet de spécifier les fréquences et les amplitudes présentes dans la texture à synthétiser. Ce spectre peut être dessiné en respectant la symétrie des quadrants mais il est également possible d'utiliser le spectre de puissance d'une texture existante.

### 3.1. BASE DE TEXTURES SOLIDES POUR L'ÉVALUATION DE MÉTHODES DE CLASSIFICATION ET DE SEGMENTATION

---

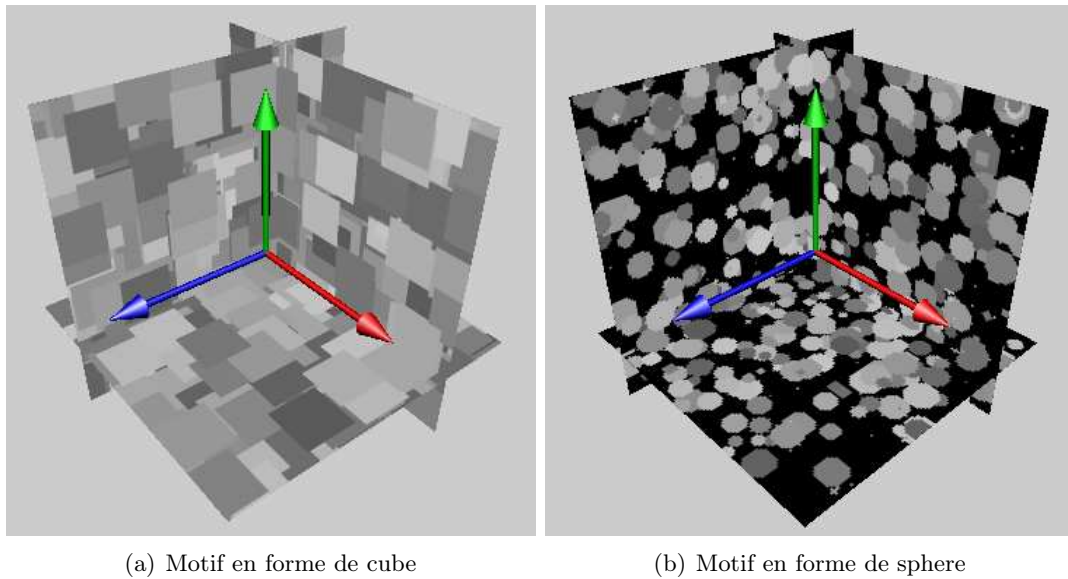


FIG. 3.2 – Textures solides construites à partir de la 2<sup>ème</sup> méthode




FIG. 3.3 – Exemple de textures solides avec des textures à l'intérieur et à l'extérieur des motifs géométriques (méthode 4)

Concernant le spectre de phase, des valeurs aléatoires peuvent être utilisées ou récupérées d'une texture existante. De cette façon, il est possible de synthétiser une texture solide à partir de la transformée inverse de Fourier. Dans [Lewis, 1984], les auteurs décrivent cette méthode de synthèse de textures comme peu intuitive. Cependant, elle permet de construire des textures qui sont riches et difficiles à obtenir dans le domaine spatial. Enfin, les textures appartenant à une même classe de textures sont générées à partir d'un unique spectre de

### 3.1. BASE DE TEXTURES SOLIDES POUR L'ÉVALUATION DE MÉTHODES DE CLASSIFICATION ET DE SEGMENTATION

---

puissance et d'un spectre de phase variable. De cette façon, les textures à l'intérieur d'une classe ne sont pas exactement identiques.

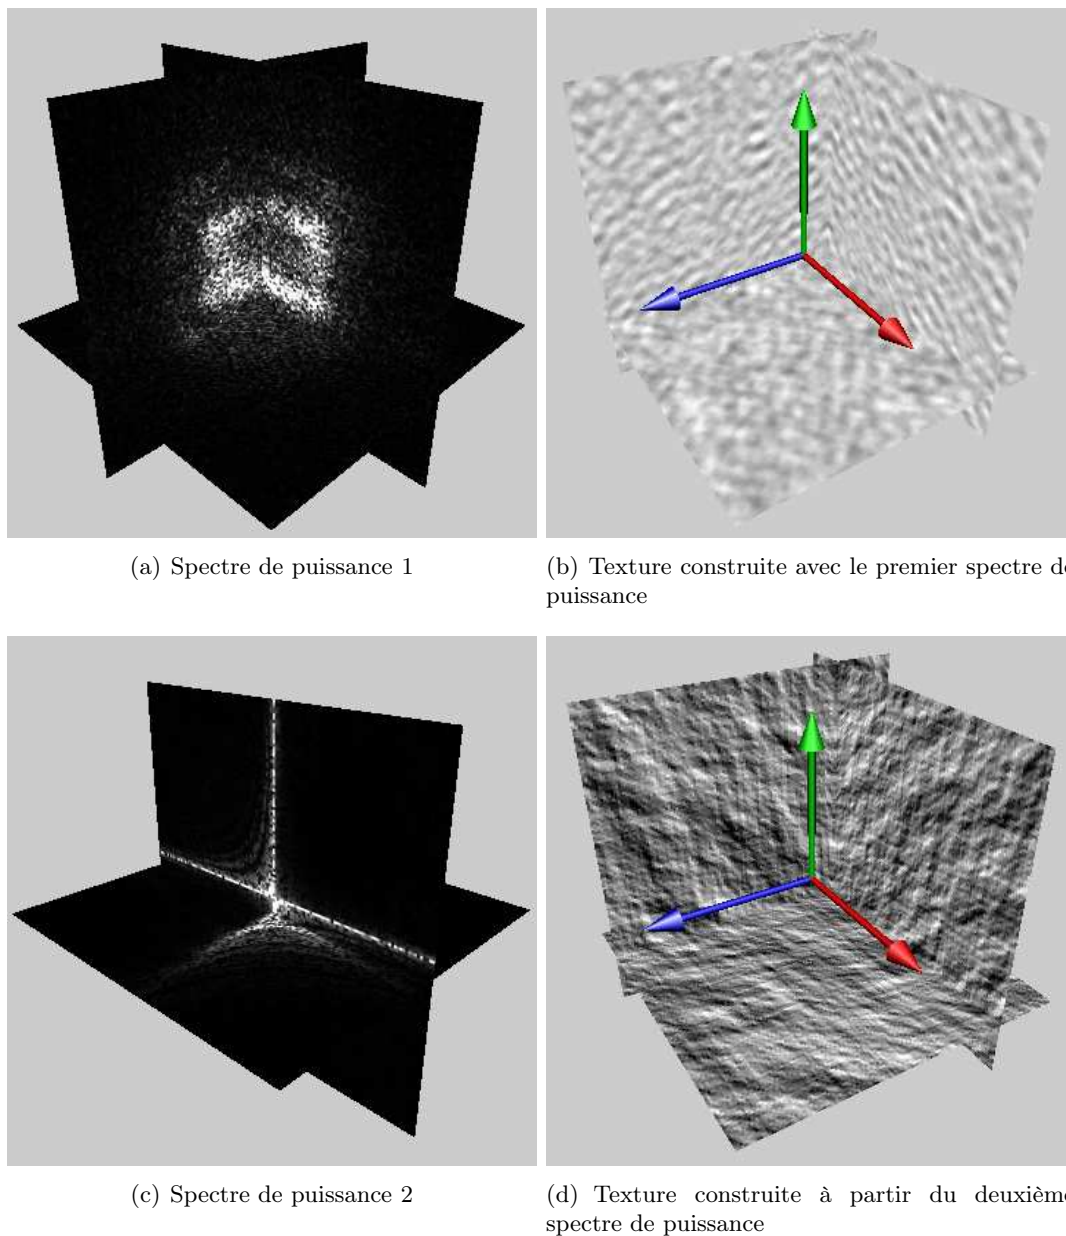


FIG. 3.4 – Exemple de textures solides construites à partir de la transformée de Fourier (méthode 3)

Enfin, il est possible d'obtenir une quatrième catégorie de textures volumétriques en utilisant les propriétés des trois méthodes précédentes. Au lieu de générer un motif avec une couleur (méthode 2), nous pouvons créer des motifs contenant une texture donnée en utilisant la première méthode de synthèse ou la transformée de Fourier inverse (Figure 3.3).

### 3.1. BASE DE TEXTURES SOLIDES POUR L'ÉVALUATION DE MÉTHODES DE CLASSIFICATION ET DE SEGMENTATION

---

Les textures ainsi générées contiennent des formes géométriques composées de textures particulières. De plus, il est possible d'insérer une texture à l'extérieur des motifs afin d'obtenir des objets qui soient texturés. Les propriétés de ce genre de textures dépendent du nombre de motifs, de leur forme et leur taille, et des textures utilisées à l'intérieur et à l'extérieur des motifs.

Afin d'augmenter les variabilités à l'intérieur de notre base, nous appliquons un certain nombre de transformations de base pour enrichir l'ensemble des classes de textures proposées. Pour chaque classe, nous disposons ainsi de textures n'ayant subi aucune transformation, de textures bruitées, de textures floutées, de textures sous-échantillonnées, et de textures avec des rotations aléatoires selon les axes  $x$ ,  $y$  et  $z$  (Figure 3.5). De cette façon, il devient possible de tester si une méthode d'analyse de textures est invariante à la rotation, de tester sa robustesse au bruit ou au flou, et de pouvoir augmenter facilement la difficulté de comparaison des images 3D de la base de données lors d'un problème d'analyse de textures. Afin d'appliquer un sous-échantillonnage, nous construisons des images 3D texturées de taille  $128^3$  qui sont ensuite sous-échantillonnées afin d'obtenir une texture solide de taille  $64^3$  contenant des motifs deux fois plus petits. Concernant les distorsions de bruit et de flou, la distribution Gaussienne est centrée en 0 et l'écart type  $\sigma$  prend la valeur 5 dans le cas du bruit Gaussien et la valeur de 1.5 dans le cas du flou Gaussien. Ces transformations sont appliquées par convolution d'une image 3D avec un masque de taille  $3^3$ .

#### 3.1.2 Organisation de la base d'images

La base de données proposée est organisée de la façon suivante : les images texturées 3D sont séparées en fonction de leur méthode de synthèse et sont partitionnées en quatre dossiers. Dans chacun d'eux, les images sont regroupées selon le type de transformations appliquées : aucune, flou Gaussien, bruit Gaussien, rotation aléatoire, sous-échantillonnage. Les sous-dossiers "transformations" contiennent l'ensemble des classes de textures générées par une méthode de synthèse.

Actuellement, notre base de données contient 95 classes différentes : 30 classes sont construites avec la méthode d'interpolation, 25 avec la méthode géométrique, 15 avec la transformée de Fourier inverse et 25 avec la méthode des motifs texturés. Chacune des classes se compose de 50 exemples de textures solides : 10 textures floues, 10 textures bruitées, 10 textures sous-échantillonnées, 10 textures avec un ensemble de rotations aléatoires et 10 textures sans aucune transformation. Une image 3D est représentée par un ensemble de 64 images BMP 2D de dimension  $64^2$  pixels. Nous avons choisi le format BMP de par l'intérêt de sa large diffusion. Il est par ailleurs utilisé et proposé dans la plupart des bases de données en image et texture. En effet, la mise en place d'un logiciel capable d'utiliser ce format est simple et rapide. Un logiciel de visualisation capable de lire les images 3D proposées dans la base est disponible sur le site web <sup>2</sup>. Afin de proposer une taille suffisamment importante pour des tests de classification, les textures volumétriques générées sont de dimension  $64^3$  pixels. Ce choix permet également un bon compromis concernant l'espace disque. Enfin, les images utilisées pour les tests de segmentation (images qui contiennent

---

<sup>2</sup>[http://www.rfai.li.univ-tours.fr/fr/ressources/3Dsynthetic\\_images\\_database.html](http://www.rfai.li.univ-tours.fr/fr/ressources/3Dsynthetic_images_database.html)



### 3.1. BASE DE TEXTURES SOLIDES POUR L'ÉVALUATION DE MÉTHODES DE CLASSIFICATION ET DE SEGMENTATION

---




FIG. 3.5 – [a-c] Textures solides avec rotation aléatoire, [d-e] Deux textures floutées, [f-g] Deux textures bruitées, [h-i] Deux textures solides sous-échantillonnées

plus d'une seule texture) ont une taille de  $128^3$  offrant un degré de liberté plus important pour l'emplacement des différentes textures solides dans l'image 3D. Ces images sont actuellement disponibles au nombre de 15 : 5 textures contenant 2 classes, 5 textures contenant 3 classes, 5 textures contenant 4 classes.

Pour chacune des images 3D générées, un fichier XML associé résume l'ensemble des caractéristiques. La racine de l'arbre XML désigne une image 3D pouvant contenir une ou

plusieurs textures solides. Pour un problème de classification les images 3D utilisées correspondent à une unique texture solide alors que pour une problématique de segmentation, les images 3D contiennent plusieurs textures volumétriques différentes. Une texture solide est définie par un conteneur (emballage), par un nom (correspondant au nom d'une classe de textures), par le type de méthode de synthèse utilisée, par l'ensemble des propriétés et transformations qui lui sont appliquées. Un conteneur est utilisé puisque dans le cas d'un problème de segmentation, une texture volumétrique n'est pas forcément définie dans un cube. Actuellement, une texture solide peut être créée à l'intérieur de trois formes différentes (cube, sphère ou ellipse), celles-ci étant caractérisées par une dimension, une localisation ainsi qu'une orientation particulière. Les propriétés sont dépendantes du type de méthode de synthèse utilisé pour construire une texture solide. Par exemple, une texture volumétrique générée à partir de la transformée de Fourier inverse dépend du spectre de puissance utilisé. Pour pouvoir diffuser et exploiter ces fichiers XML, nous avons créé un fichier DTD disponible en partie en annexe C.

Cette base de données est actuellement disponible en accès libre <sup>2</sup> sur le web. De ce fait, un chercheur peut l'utiliser pour évaluer des méthodes d'analyse de textures solides à l'aide d'expérimentations de classification ou de segmentations. Il est bien sûr possible de compléter cette base de données avec d'autres méthodes de synthèse le but étant d'accroître le nombre de classes et d'images. Actuellement cette base de données contient 95 classes différentes ce qui est suffisant si nous comparons avec les bases de textures 2D. Par exemple, la base de Brodatz [Brodatz, 1966], qui constitue un standard pour l'évaluation d'algorithmes, contient 112 classes différentes.

### 3.2 Extension 3D de la méthode des motifs binaires (LBP)

Dans la littérature, nous n'avons pas trouvé d'extension 3D de la méthode des motifs binaires (*local binary pattern*). C'est pourquoi dans [Paulhac *et al.*, 2008], nous avons proposé une extension de cette méthode au domaine 3D. Le but de ce travail était de démontrer l'intérêt d'une approche vraiment 3D (LBP 3D) en comparaison de son équivalent 2D. Pour cela nous avons mis en place un protocole d'évaluation en classification utilisant notre base de textures solides. Ces méthodes sont testées selon plusieurs cas de figure avec une base de test contenant des textures sans aucune transformation, une base de test bruitée, et une base de test de textures avec rotations. Sur l'ensemble des tests réalisés, l'approche 3D se révèle être plus robuste avec des différences considérables concernant la troisième base de test. L'intérêt majeur de la méthode LBP 3D par rapport à la méthode LBP 2D est qu'elle conserve la propriété d'invariance à la rotation dans le domaine 3D.

L'algorithme classique LBP 2D [Ojala *et al.*, 1996] permet de calculer jusqu'à  $2^8$  unités de textures (avec  $R = 1$ ), seulement dans le domaine 3D, le nombre de motifs augmente de façon considérable avec  $2^{26} = 6.7108864 \times 10^7$  unités de textures possibles. C'est la raison pour laquelle nous avons choisi de baser notre extension 3D sur la méthode LBP proposée dans [Ojala et Pietikäinen, 2002] où le nombre de motifs possibles est de  $P + 2$  avec  $P$  le

---

<sup>2</sup>[http://www.rfai.li.univ-tours.fr/fr/ressources/3Dsynthetic\\_images\\_database.html](http://www.rfai.li.univ-tours.fr/fr/ressources/3Dsynthetic_images_database.html)

### 3.2. EXTENSION 3D DE LA MÉTHODE DES MOTIFS BINAIRES (LBP)

nombre de voisins pour une unité de textures. De plus, cette méthode possède la propriété d'être invariante à la rotation.

En 2D, nous avons vu dans la partie état de l'art que le voisinage autour d'un pixel central, est réparti de façon circulaire. En respectant ce raisonnement, nous avons choisi de définir le voisinage d'un voxel central sur une sphère afin de proposer une méthode LBP 3D. Cette sphère est construite de la façon suivante : pour un voxel central  $g_c$  ayant comme coordonnée  $(0, 0, 0)$ , les coordonnées de  $g_{pp'}$  sont données par  $(R \cos(\pi p'/(S - 1)) \cos(2\pi p/P), R \cos(\pi p'/(S - 1)) \sin(2\pi p/P), R \sin(p'\pi)/(S - 1))$  avec  $R$  le rayon de la sphère,  $S$  le nombre de cercles utilisés pour construire la sphère, et  $P$  le nombre de vertex dans chaque cercle (Figure 3.6). Le voisinage ainsi construit, l'opérateur de textures LBP 3D peut être défini de la façon suivante :

$$LBP_{P',R}^{riu2} = \begin{cases} \sum_{p=0}^{P'-1} s(g_p - g_c) & \text{if } U(LBP_{P',R}) \leq V \\ P' + 1 & \text{sinon} \end{cases} \quad (3.2)$$

avec  $P' = (S - 2) \times P + 2$ ,

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.3)$$

De la même façon qu'en 2D,  $U$  est une fonction de mesure d'uniformité qui compte le nombre de régions uniformes noires et blanches présentes sur un motif LBP 3D. Afin de permettre le bon fonctionnement de cette fonction, nous construisons un graphe à partir de tous les vertex de la sphère. Chacun des vertex de la sphère est connecté à ses plus proches voisins de façon à obtenir un graphe qui soit connexe. En utilisant ce graphe, nous appliquons un algorithme de croissance de région pour identifier les différentes régions présentes sur un motif 3D. En 2D, un motif est défini comme uniforme si le nombre de régions est inférieur ou égal à 2. En 3D, nous avons relaxé cette condition avec  $V \in \{2, 3\}$ . Si  $V = 3$ , sont considérés comme uniforme les motifs dont le nombre de régions est inférieur ou égal à 3. Nous proposons d'alléger la condition d'uniformité car lorsque le rayon de la sphère augmente, la proportion des motifs uniformes diminue de façon importante (Table 3.1). Avec un rayon  $R = 3$  et avec  $V = 2$ , le pourcentage de motifs uniformes est inférieur à 50%. En conséquence, il est possible de perdre un grand nombre d'informations sur une texture.

	V=2	V=3
R=1,P'=26	90.01	96.22
R=2,P'=98	59.92	80.36
R=3,P'=218	46.01	61.28

TAB. 3.1 – Pourcentage des motifs uniformes

Avec cette méthode, nous sommes capables de construire un code LBP sur des images texturées 3D. Cependant, en 2D le code  $LBP_{P,R}^{riu2}$  correspond à un unique motif LBP alors qu'avec notre méthode 3D plusieurs motifs LBP sont identifiés par un même code (Figure 3.7). Il est donc possible de trouver deux textures différentes qui génèrent le même histogramme LBP. Idéalement, il faudrait calculer un code unique pour chaque motif uniforme

### 3.2. EXTENSION 3D DE LA MÉTHODE DES MOTIFS BINAIRES (LBP)

---




FIG. 3.6 – Représentation d'un motif local binaire 3D ( $S=9$ ,  $R=2$ ,  $P=16$ )

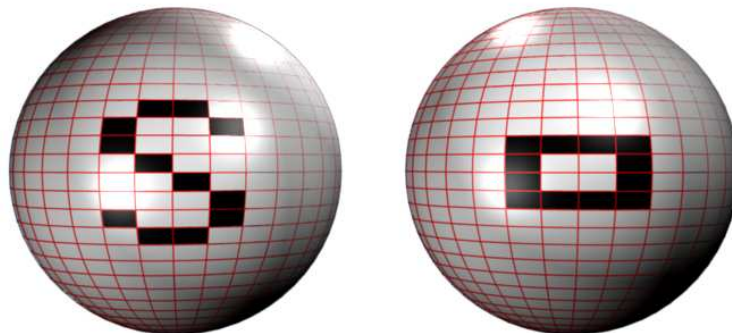


FIG. 3.7 – Exemple de deux motifs LBP 3D ayant le même code LBP ( $LBP_{P',R}^{riu_2} = 12$ ). Ici, la valeur des vertex en noir est égale à 1 alors que la valeur des autres vertex est de 0.

de la même façon qu'en 2D. Cependant, le nombre de codes LBP possibles augmenterait de façon considérable.

### 3.3 Expérimentations en classification

Les images 3D ne contenant qu'une seule texture volumétrique peuvent être utilisées dans le cadre d'une problématique de classification. Il s'agit alors de déterminer la classe d'appartenance d'une texture à partir de descripteurs et d'algorithmes de classification. Les images contenant plusieurs textures solides peuvent aussi être utilisées en classification. L'objectif est alors d'attribuer un label à un voxel pour aboutir à une segmentation. Un grand nombre de méthodes ont été proposées pour l'évaluation des algorithmes de segmentation et de classification [Zhang, 1996]. Dans le prochain paragraphe, nous faisons une revue rapide de quelques-unes de ces méthodes d'évaluation.

#### 3.3.1 Évaluation d'algorithmes de classification d'images

Le but d'un système de classification est de décider la classe d'appartenance d'une image donnée. De façon générale, un système de classification est constitué de trois parties principales. La première consiste à extraire de l'image traitée un ensemble de caractéristiques. Dans le cadre d'un problème de reconnaissance de textures, nous avons vu dans l'état de l'art les descripteurs les plus souvent utilisés [Haralick *et al.*, 1973, Chellappa et Jain, 1993, Mallat, 1989, Ojala *et al.*, 1996]. La deuxième étape consiste à sélectionner les caractéristiques ce qui permet de réduire l'espace de description tout en gardant les caractéristiques les plus significatives. Durant la dernière étape, les vecteurs de caractéristiques sont soumis à des algorithmes de classification comme les réseaux de neurones, les machines à vecteurs de support, les  $k$  plus proches voisins, etc., afin de produire une décision. Une phase d'apprentissage permet au classificateur d'apprendre les caractéristiques de chaque classe. Durant une seconde phase, l'algorithme de classification étiquette les images de la base de test à partir de ce qu'il a appris.

Afin d'évaluer des systèmes de classification et de comparer leur robustesse pour une application donnée, une approche classique consiste à exploiter la matrice de confusion qui représente le nombre d'éléments  $c_{i,j}$  de la classe  $i$  classifiés à l'intérieur de la classe  $j$ . La matrice de confusion normalisée  $NCM$  peut être calculée de la façon suivante :

$$NCM_{i,j} = \frac{c_{i,j}}{\sum_{k=1}^T c_{i,k}} \quad (3.4)$$

avec  $T$  le nombre de classes considérées.

En utilisant cette matrice, il est alors possible de calculer plusieurs mesures :

le taux de vrais positifs,

$$TPrate_i = NCM_{i,i} \quad (3.5)$$

le taux de faux positifs,

$$FPrate_i = \sum_{j=1, j \neq i}^T NCM_{i,j} \quad (3.6)$$

l'exactitude,

$$Accuracy = \frac{\sum_{i=1}^T NCM_{i,i}}{T} \quad (3.7)$$

le taux d'erreur de classification  $ECR$  avec par exemple :

$$ECR = \sum_{i=1}^T \frac{0.5(\sum_{j=1, j \neq i}^T NCM_{i,j} + \sum_{j=1, j \neq i}^T \frac{NCM_{j,i}}{T-1})}{T} \quad (3.8)$$

Le taux ECR considère deux types d'erreurs : les éléments d'une classe  $i$  faussement classifiés comme éléments d'une autre classe et les éléments classifiés dans une classe donnée  $j$  mais appartenant à une autre classe  $i$ .

Dans [Martin *et al.*, 2006], les auteurs proposent une approche intéressante qui consiste en la construction d'une matrice de confusion prenant en considération plusieurs vérités terrains traduisant les contradictions entre experts. Cette méthode est intéressante dans le cadre d'analyses d'images naturelles nécessitant habituellement plusieurs classifications expertes.

Une autre façon d'examiner la performance d'un ensemble de classificateurs est l'utilisation des graphes ROC (*receiver operating characteristics graph*) qui permettent de visualiser et de sélectionner un ensemble de classificateur en se basant sur leur performance. Les graphes ROC sont des graphes 2D dans lequel l'axe des ordonnées  $TPrate$  (formule 3.5) représente le taux de vrai positifs et l'axe des abscisses  $FPrate$  (formule 3.6) représente le taux de faux positifs d'un classificateur. Si  $T$  classes sont considérées, alors il est possible de générer  $T$  graphiques. Pour chaque classificateur, nous pouvons calculer une paire  $(FPrate, TPrate)$ , ce qui permet la comparaison de leur performance (Figure 3.8). Le point  $(0, 1)$ , désigné par le classificateur C, représente une classification parfaite. Pour plus d'information sur les méthodes d'analyse associées aux graphes ROC, Fawcett présente un guide sur leur utilisation en recherche afin de promouvoir des pratiques de l'évaluation qui soient meilleures [Fawcett, 2006].

Il existe un grand nombre d'autres méthodes pour l'évaluation de systèmes de classification passé en revue dans [Ferri *et al.*, 2008]. Les auteurs proposent une description et une étude des relations entre les mesures de performance les plus couramment utilisées en classification. Ils relèvent une similarité importante entre les différentes mesures mais également des différences significatives entre certaines.

#### 3.3.2 Évaluation de nos descripteurs en classification

Nous comparons, dans une problématique de classification, notre méthode HUF (*Human Understandable Features*) avec les matrices de cooccurrence d'Haralick [Haralick, 1979, Haralick *et al.*, 1973], la méthode LBP 2D présentée dans [Ojala et Pietikäinen, 2002] et notre extension 3D de la méthode LBP [Paulhac *et al.*, 2008]. Pour cela nous utilisons notre base de données de textures solides [Paulhac *et al.*, 2009] contenant 95 classes de textures différentes. Pour ces expérimentations de classification, nous utilisons l'algorithme machine à vecteurs de support (SVM) avec un noyau RBF (*radial basic function*)  $K(x, x') = \exp(-\gamma \|x - x'\|^2)$  avec  $x$  et  $x'$  deux vecteurs de dimensions  $p$  et  $\gamma > 0$ . Ce type de noyau permet d'envisager le cas où la relation entre les différentes classes n'est pas linéaire. De plus, le nombre de paramètres est faible si nous comparons avec d'autres noyaux comme le noyau polynomial. Dans notre implémentation, nous utilisons une librairie gratuite disponible sur le web et appelée "LIBSVM" [Chang et Lin, 2001]. Durant nos tests de classification, nous utilisons quatre




FIG. 3.8 – Un exemple de graphe ROC

images 3D par classe pour la phase d'apprentissage et six images 3D pour la phase de test. Pour calculer les caractéristiques d'Haralick, nous calculons une matrice de cooccurrence selon 13 directions ce qui permet d'obtenir une description plus riche [Haralick, 1979, Haralick *et al.*, 1973]. Dans ces tests nous utilisons les 14 caractéristiques d'Haralick présentées en annexe A. Cette méthode comprend deux paramètres : il s'agit de la distance entre voxels  $d$  et du paramètre de quantification  $q$  des niveaux de gris. Pour la méthode LBP 3D nous proposons, de façon identique à [Ojala et Pietikäinen, 2002], de tester l'opérateur  $LBP_{P,R}^{riu2}$  selon trois résolutions spatiales différentes et trois résolutions angulaires. Pour une valeur de rayon donnée, si le nombre de vertex est trop peu important, alors la probabilité d'obtenir des motifs uniformes est restreinte. En 3D, nous calculons les trois opérateurs suivants avec  $LBP_{26,1}^{riu2}$ ,  $LBP_{98,2}^{riu2}$  et  $LBP_{218,3}^{riu2}$  en considérant  $V \in \{2, 3\}$ . En 2D, les opérateurs  $LBP_{8,1}^{riu2}$ ,  $LBP_{16,2}^{riu2}$  et  $LBP_{32,3}^{riu2}$  sont calculés pour chaque image 2D dans le plan  $(x, y)$  de chaque texture volumétrique. Concernant la méthode HUF nous utilisons plusieurs ondelettes avec les ondelettes de Haar et Daubechie [Unser, 1995] ainsi que plusieurs résolutions. De plus, l'ensemble des caractéristiques proposées dans le chapitre 2 sont utilisées : la granularité, le volume, la compacité, la régularité, le contraste, la rugosité, la directionnalité. Afin d'évaluer la performance des différentes méthodes utilisées, nous présentons les pourcentages de reconnaissance, calculés à l'aide d'une matrice de confusion (formule 3.7) et sur l'ensemble des bases de test proposées.

Dans la section précédente, nous avons vu que notre base de données contenait 95 classes de textures solides différentes et que pour chacune d'elles plusieurs exemples de textures étaient disponibles, avec des textures normales sans aucune transformation et des

### 3.3. EXPÉRIMENTATIONS EN CLASSIFICATION

---

	q=8	q=16	q=32	q=64	q=128
d=1	69.81	58.34	31.63	19.85	8.43
d=2	63.09	38.84	21.44	8.78	2.63
d=3	52.02	26.36	14.76	5.44	2.10

TAB. 3.2 – Pourcentage de reconnaissance avec les 14 caractéristiques d’Haralick sur la base de test sans bruit (95 classes, 4 images d’apprentissage et 6 images de test par classe).

	q=8	q=16	q=32	q=64	q=128
d=1	50.96	35.85	17.39	10.54	4.50
d=2	44.11	22.84	11.95	5.62	1.93
d=3	35.67	14.41	8.78	3.33	1.58

TAB. 3.3 – Pourcentage de reconnaissance avec les 14 caractéristiques d’Haralick sur la base de test contenant à la fois des images normales et bruitées (95 classes, 4 images d’apprentissage et 6 images de test par classe).

	V=2	V=3
R=1,P'=26	85.87	86.04
R=2,P'=98	89.91	86.75
R=3,P'=218	88.68	83.83

TAB. 3.4 – Pourcentage de reconnaissance avec la méthode LBP 3D sur la base de test sans bruit ( $P'$  caractéristiques, 95 classes, 4 images d’apprentissage et 6 images de test par classe).

	V=2	V=3
R=1,P'=26	47.62	46.74
R=2,P'=98	52.37	48.11
R=3,P'=218	50.26	46.39

TAB. 3.5 – Pourcentage de reconnaissance avec la méthode LBP 3D sur la base de test contenant à la fois des images normales et bruitées ( $P'$  caractéristiques, 95 classes, 4 images d’apprentissage et 6 images de test par classe).

	Base normale	Base normale + bruit
R=1,P=8	85.21	47.14
R=2,P=16	89.14	52.02
R=3,P=32	88.68	48.94

TAB. 3.6 – Pourcentage de reconnaissance avec la méthode LBP 2D sur les deux bases de test ( $P$  caractéristiques, 95 classes, 4 images d’apprentissage et 6 images de test par classe).

textures avec des distorsions comprenant des textures bruitées, des textures floutées, des textures sous-échantillonnées ainsi que des textures ayant subi des rotations aléatoires selon les trois axes  $x$ ,  $y$  et  $z$ . Durant nos tests, nous utilisons une base d’apprentissage et deux



### 3.3. EXPÉRIMENTATIONS EN CLASSIFICATION

---

	haar	db2	db4	db6	db8
$\beta = 1$	60.36	62.45	63.33	61.57	60.87
$\beta = 2$	68.78	68.08	70.71	69.48	69.31

TAB. 3.7 – Pourcentage de reconnaissance avec notre méthode HUF sur la base de test contenant des images normales ( $7\beta$  caractéristiques, 95 classes, 4 images d’apprentissage et 6 images de test par classe).

	haar	db2	db4	db6	db8
$\beta = 1$	44.46	46.22	46.92	43.40	41.82
$\beta = 2$	53.77	53.42	53.77	54.13	53.07

TAB. 3.8 – Pourcentage de reconnaissance avec notre méthode HUF sur la base de test contenant à la fois des images normales et bruitées ( $7\beta$  caractéristiques, 95 classes, 4 images d’apprentissage et 6 images de test par classe).

bases de tests différentes. Notre base d’apprentissage contient, pour chaque classe de textures, quatre exemples différents de textures n’ayant subi aucune transformation (texture normale). Concernant les deux bases de tests utilisées, la première contient, pour chaque classe de textures solides représentées, six textures volumétriques normales (sans transformations) alors que la deuxième contient trois textures normales mais également trois textures bruitées. Les résultats de classification obtenus sur la première base de test par l’ensemble des méthodes sont présentés dans la table 3.2 (résultats avec les caractéristiques d’Haralick), la table 3.4 (résultats avec LBP 3D), la table 3.6 (résultats avec LBP 2D) et la table 3.7 (résultats avec notre méthode HUF). Celles-ci représentent le pourcentage de reconnaissance (formule 3.7) des textures solides sur l’ensemble de la base de test.

Comme nous pouvons le constater, la méthode des motifs binaires 3D donne les meilleurs résultats de classification (environ 90%) suivie de près par la méthode LBP 2D. La méthode HUF permet d’obtenir des résultats de classification légèrement supérieurs (70%) à ceux obtenus à partir des caractéristiques d’Haralick. Avec la méthode LBP 3D, les meilleurs résultats sont obtenus avec l’opérateur  $LBP_{98,2}^{riu2}$  et le paramètre d’uniformité  $V = 2$ . Si nous comparons avec la méthode LBP 2D, les résultats de classifications sont relativement proches. Le gros intérêt de la méthode LBP 3D par rapport à la méthode LBP 2D est qu’elle permet de conserver la propriété d’invariance à la rotation dans le domaine 3D. Concernant la méthode des matrices de cooccurrence d’Haralick, le meilleur résultat de classification est obtenu avec une distance  $d = 1$  et avec le paramètre de quantification  $q = 8$ . Nous pouvons également constater que lorsque les paramètres de distance et notamment de quantification augmentent, les résultats de classification s’effondrent de façon importante. Enfin notre méthode présente des résultats de classification relativement stable quelle que soit l’ondelette choisie. Nous pouvons également souligner l’importance de la multirésolution qui permet une forte amélioration des résultats de classification.

Sur la base de test contenant des images bruitées, les meilleurs résultats sont obtenus avec la méthode HUF (54%). Les méthodes LBP 2D et 3D présentent de fortes difficultés à reconnaître les textures volumétriques ayant subi une distorsion (52%). En effet, les histogrammes générés à partir des images bruitées présentent d’importants changements dans la répartition des motifs binaires. Les caractéristiques d’Haralick fournissent les moins

bons résultats et se comportent de façon similaire à l'expérimentation sur la base de test précédente en présentant des résultats de classification qui chutent au fur et à mesure de l'augmentation des paramètres de distance  $d$  et de quantification  $q$ . Si nous comparons avec la base de test contenant des textures normales, la chute la plus importante des taux de classification concerne les méthodes LBP 2D et 3D car celles-ci se révèlent peu robustes sur la plupart des textures bruitées. Enfin, la multirésolution permet également d'améliorer les résultats de classification de notre méthode HUF de façon significative.

## 3.4 Expérimentations en segmentation

### 3.4.1 Évaluation d'algorithmes de segmentation d'images

Les méthodes comme les matrices de confusion permettent uniquement d'évaluer les approches de classification mais ne donnent pas d'évaluation de la segmentation produite [Martin *et al.*, 2006]. L'évaluation d'une segmentation ne peut se satisfaire uniquement d'une comparaison visuelle et nécessite l'utilisation de métriques. Plusieurs méthodes ont été proposées et celles-ci sont réparties selon deux familles : les méthodes d'évaluation supervisées qui nécessitent l'accès à une vérité terrain et les méthodes d'évaluation non-supervisées qui ne nécessitent aucune connaissance *a priori*.

Les méthodes d'évaluation supervisées mesurent le degré de similarité entre une ou plusieurs segmentations expertes et la segmentation générée par un algorithme. Le principal avantage de ce genre de méthodes est qu'elles permettent d'obtenir une évaluation très fine. Cependant, la génération d'une vérité terrain peut, dans certains cas, se révéler très difficile à obtenir. Son temps de construction est également une contrainte non négligeable surtout dans le domaine des images 3D. Ce problème ne se pose pas pour notre base de données de textures solides puisqu'il s'agit d'images de synthèse pour lesquelles il est facile de construire les vérités terrain à partir des informations contenues dans les fichiers xml (figure 3.9). Par ailleurs, durant l'évaluation d'une segmentation, plusieurs types d'erreurs peuvent être considérées : la sous-segmentation (des éléments sont manquants), la sur-segmentation (supplément de pixels/voxels), et enfin l'erreur de localisation. Dans [Chabrier *et al.*, 2008], une étude comparative de 14 critères d'évaluations supervisés est réalisée. Ceux-ci sont étudiés dans différentes conditions de dégradation (sous-segmentation, sur-segmentation, etc.). En conclusion de cet article, le critère de *Pratt* se révèle être le plus efficace en moyenne.

Les critères présentés dans [Chabrier *et al.*, 2008] correspondent à des méthodes permettant d'évaluer une segmentation à partir de la frontière des régions présentes dans une image. D'autres mesures permettent de donner une évaluation en se basant sur une métrique qui compare les différentes régions et non directement les frontières. C'est le cas de la mesure générique d'anomalie (*generic discrepancy measure*) [Cardoso et Corte-Real, 2005] que nous utiliserons pour nos évaluations. Celle-ci est basée sur la distance de partition qui est définie dans [Gusfield, 2002] de plusieurs façons :

**Definition 3.4.1.** *Étant donné deux partitions  $P$  et  $Q$  de  $S$ , la distance de partition correspond au nombre minimum d'éléments devant être supprimés de  $S$  de manière à ce*

que  $P$  et  $Q$  (restreint aux éléments restants) soient identiques.

**Definition 3.4.2.** La distance de partition est égale au nombre minimum d'éléments qui doivent être déplacés entre cluster dans  $P$  de façon à ce que la partition résultante soit égale à  $Q$ .

La mesure générique d'anomalie correspond à la distance de partition normalisée. Si nous considérons deux partitions  $P$  et  $Q$ , alors la mesure générique d'anomalie  $d_{ga}$  est définie de la façon suivante :

$$d_{ga} = d_{sym}(P, Q)/(N - 1) \quad (3.9)$$

avec  $N$  le nombre de pixels/voxels de l'image et  $d_{sym}$  la distance de partition.

Si la mesure générique normalisée est égale à 0, alors la segmentation générée est parfaite. A l'inverse, si tous les voxels sont étiquetés comme appartenant à la mauvaise région alors la mesure générique normalisée prendra la valeur de 1. Ce dernier cas de figure n'est possible que si  $P$  correspond à la partition nulle et  $Q$  à la partition infinie ou inversement.

Les méthodes d'évaluations non-supervisées permettent une évaluation quantitative et objective sans pour autant nécessiter de références. Ce genre de méthode est très intéressant dans certains types d'applications où il est parfois difficile, voire impossible, de construire une vérité terrain. Par exemple, générer une vérité terrain pour les images échographiques 3D est très difficile de par leur structure complexe mais également de par leur grande dimension. Beaucoup de métriques ont été présentées et certaines d'entre elles proposent de mesurer l'uniformité intra-région, la disparité inter-région, la forme, etc. Dans [Zhang *et al.*, 2008], les auteurs proposent un état de l'art de ces méthodes non-supervisées dans lequel sont présentées des expérimentations afin de les évaluer dans différentes situations. Nous ne nous étendons pas ici sur ce type de méthodes puisque nous ne les avons pas utilisées. En effet, elles ne sont généralement pas adaptées aux images texturées.

#### 3.4.2 Évaluation de nos descripteurs

Afin d'évaluer notre méthode (HUF : *Human Understandable Features*) dans une problématique de segmentation, nous avons choisi de la comparer avec deux méthodes classiques et performantes de la littérature : les matrices de cooccurrence d'Haralik (GLCM) [Haralick, 1979, Haralick *et al.*, 1973] et la méthode LBP 3D [Paulhac *et al.*, 2008]. Les résultats de segmentation sont produits en utilisant 15 textures solides différentes (Figure 3.10) générées à partir des textures présentes dans notre base de données. Parmi elles, 5 images 3D contiennent 2 classes de textures, 5 images 3D contiennent 3 classes de textures et les 5 dernières images 3D contiennent 4 classes de textures.

Les matrices de cooccurrence d'Haralik sont calculées selon 13 directions dans l'espace 3D. Le fait de construire une matrice selon plusieurs directions permet d'obtenir une matrice plus générale et plus représentative des textures présentes dans une image [Haralick, 1979, Haralick *et al.*, 1973]. A partir de cette matrice, nous avons calculé 14 caractéristiques différentes, classiquement utilisées, et dont les méthodes de calculs sont présentées en annexe A. Comme dans la partie classification, nous faisons varier les deux

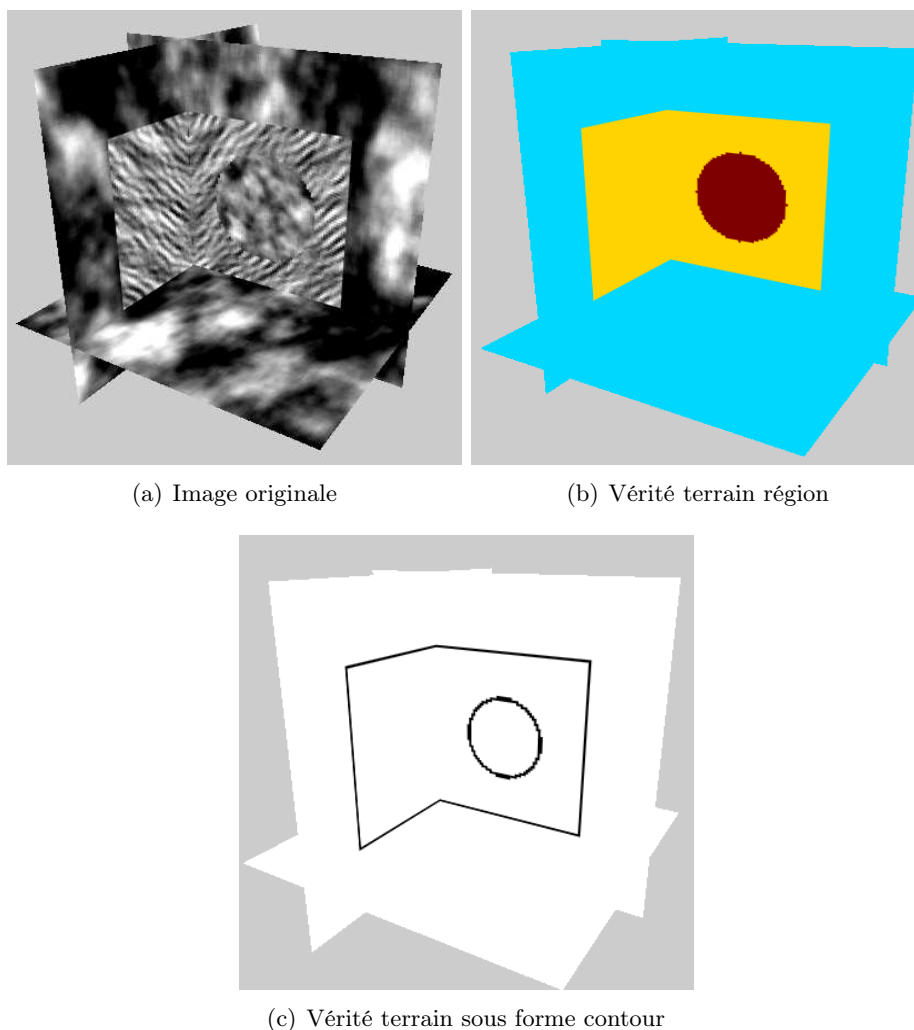



FIG. 3.9 – Exemple d’une image 3D contenant 3 textures solides avec ses vérités terrains associées


paramètres de cette méthode avec la distance  $d$  entre deux voxels et le paramètre de quantification  $q$ . Concernant notre méthode, l’ensemble des caractéristiques est utilisé comme dans la section précédente de classification. Des segmentations sont générées en faisant varier le nombre de résolutions  $\beta$  et en utilisant différentes ondelettes (haar, daubechie). Pour la méthode LBP 3D, nous proposons de calculer deux opérateurs différents avec  $LBP_{26,1}^{riu2}$ ,  $LBP_{98,2}^{riu2}$ . Enfin nous faisons varier le paramètre de régionalité  $N$  (voisinage autour d’un voxel), paramètre commun à chacune des trois méthodes. Dans la sous-section 3.4.2.1 suivante, nous expliquons comment les descripteurs HUF sont intégrés à l’intérieur d’un schéma de segmentation multirésolution.

### 3.4. EXPÉRIMENTATIONS EN SEGMENTATION


---




(a)




(b)




(c)




(d)




(e)




(f)




(g)




(h)




(i)



(j)



(k)



(l)




FIG. 3.10 – Images de textures volumétriques : [a-e] 2 classes de textures, [f-j] 3 classes de textures, [k-o] 4 classes de textures

### 3.4.2.1 Schéma de segmentation multirésolution avec les descripteurs HUF

L'approche proposée permet d'obtenir l'ensemble des caractéristiques de textures présentées dans le chapitre 2 et ceci sur plusieurs résolutions. Pour cela, nous avons vu qu'une décomposition en ondelette discrète est utilisée et que les caractéristiques de textures sont calculées à partir des sous-bandes coefficient de détail et d'approximation. Dans le cadre d'une segmentation, les caractéristiques de textures proposées sont calculées pour chacun des voxels de l'image à traiter. Afin d'avoir le même nombre d'attributs de textures, quelle que soit la résolution, il est nécessaire de sur-échantillonner l'ensemble des caractéristiques de textures, et ceci pour chaque résolution (Figure 3.11).

Un voxel est alors décrit par un vecteur contenant un ensemble d'attributs de textures. Un vecteur est composé par un maximum de  $7n$  caractéristiques de textures différentes avec  $n$  le nombre de résolutions choisi et 7 le nombre des caractéristiques de textures proposé : la granularité ( $f_{gran}$ ), les informations de forme sur les motifs d'une texture ( $f_{vol}$  et  $f_{comp}$ ), la régularité ( $f_{reg}$ ), le contraste ( $f_{con}$ ), la rugosité ( $f_{rug}$ ) et la directionnalité ( $f_{dir}$ ). Afin de produire une segmentation de l'ensemble des voxels, nous utilisons l'algorithme des K-means [Coleman et Andrews, 1979]. Celui-ci permet de classifier les voxels en sous-ensembles selon la valeur de leurs caractéristiques de textures. Les principaux avantages de cette méthode sont sa rapidité d'exécution et son faible coût en mémoire. Les images volumétriques sont souvent composées d'un grand nombre d'individus. Dans cette thèse, nous avons traité des images échographiques 3D de dimension  $300^3$  ce qui représente un grand nombre de voxels à classer. Il est donc nécessaire d'utiliser un algorithme de segmentation rapide et peu gourmand en mémoire. En terme de performance, l'algorithme des K-means ne garantit pas le retour de l'optimum global cependant il permet une classification efficace des voxels en très peu de temps. Cette méthode requiert donc le choix d'un nombre de classes attendues. Afin d'apporter une solution à ce problème, notre logiciel offre la possibilité de fusionner les différentes classes produites par l'algorithme des K-means *a posteriori*. Ainsi, l'utilisateur choisit, dans un premier temps, un grand nombre de classes pour produire une première segmentation (sur-segmentation). Par la suite, il peut choisir la segmentation la plus appropriée par visualisation et fusions de différentes classes. La fusion

### 3.4. EXPÉRIMENTATIONS EN SEGMENTATION

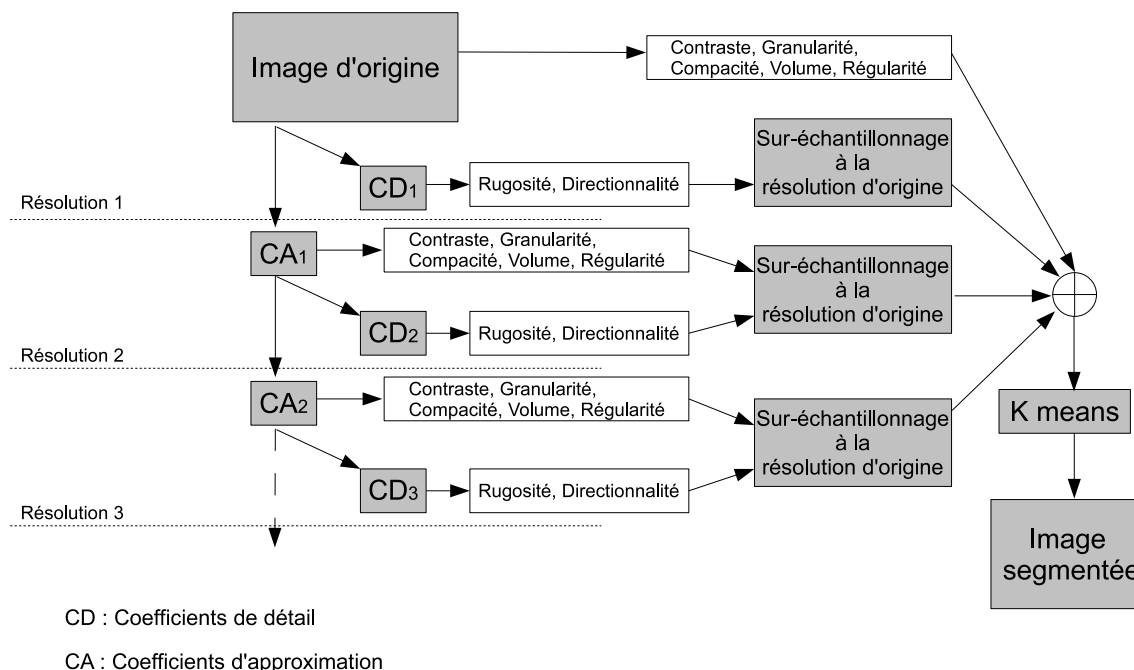



FIG. 3.11 – Schéma de segmentation multirésolution

des classes est réalisée en utilisant une classification ascendante hiérarchique à l'intérieur de laquelle les deux régions les plus proches sont fusionnées à chaque étape (Figure 3.12). La distance entre les régions est calculée en utilisant les caractéristiques de textures des centroïdes de chaque classe.

#### 3.4.2.2 Présentation des résultats de segmentation

Précédemment, nous avons vu que l'algorithme des K-means est utilisé afin de générer une segmentation. Cette méthode permet d'obtenir une classification des voxels en leur affectant une classe en fonction de leurs caractéristiques de textures. Dans le cadre de l'évaluation proposée ici, le couplage segmentation par l'algorithme des K-means et classification ascendante hiérarchique est également utilisé pour les méthodes LBP et GLCM. Pour chaque segmentation générée, l'utilisateur choisit le nombre de fusions nécessaire afin d'être le plus proche possible de la vérité terrain associée à l'image 3D traitée. Afin d'obtenir une évaluation des segmentations produites, nous avons choisi d'utiliser une métrique basée sur la comparaison de régions proposée dans [Cardoso et Corte-Real, 2005] (voir section 3.4).

Les résultats de segmentation sont présentés à partir de trois tables : la table 3.9 qui présente des résultats d'évaluation, calculés en utilisant des images 3D contenant 2 classes ; la table 3.10 dont les résultats sont calculés à partir de segmentation sur des images 3D contenant 3 classes ; et la table 3.11 qui illustre la qualité de segmentation obtenue sur des images 3D contenant 4 classes. Afin d'avoir une meilleure lisibilité, les résultats de distance

FIG. 3.12 – Exemple de segmentation avec  $K = 10$  et en fusionnant jusqu'à  $K = 2$ 

obtenus avec la mesure générique d'anomalie sont multipliés par 100 et sont compris entre 0 et 100.

Sur l'ensemble des segmentations présentées dans les tables 3.9, 3.10 et 3.11, les résultats de segmentation obtenus à partir des caractéristiques d'Haralick sont d'un point de vue quantitatif, en dessous des méthodes LBP 3D et HUF. Nous pouvons souligner le bon fonctionnement de cette approche sur des textures fines. La méthode GLCM se comporte de façon identique en classification et en segmentation avec une diminution importante des résultats lorsque la distance entre les paires de voxels augmente. Par exemple, sur la texture (b), la méthode GLCM obtient une valeur d'évaluation médiocre de 42,33 pour les paramètres  $d = 2$  et  $N = 9$  alors qu'elle génère une bonne segmentation avec une distance de 0,87 pour les paramètres  $d = 1$  et  $N = 9$ . Sur une grande partie des segmentations présentées, les moins bons résultats sont obtenus avec la méthode GLCM et pour une distance  $d = 2$ . Les méthodes LBP et HUF permettent d'obtenir les meilleurs résultats de



### 3.5. QUELQUES MOTS SUR LES TEMPS DE CALCUL ET LA NORMALISATION DES DONNÉES

---

segmentation avec un avantage pour la méthode HUF si nous considérons l'ensemble des textures utilisées dans ces tests de segmentation. Sur des textures relativement simples à segmenter, comme les textures (b), (c), (g) et (i), la méthode LBP 3D permet d'obtenir de très bons résultats qui restent proches de ceux obtenus avec la méthode HUF. En revanche, sur certaines textures plus complexes, comme les textures (m) et (n), la méthode LBP 3D est surpassée par la méthode HUF. En effet, la méthode HUF fournit de bons résultats sur l'ensemble des textures volumétriques, et dans le cas de textures très complexes, les résultats de segmentation sont très bons en comparaison aux méthodes GLCM et LBP 3D. Avec la méthode HUF, nous avons également effectué des segmentations en considérant deux niveaux de décomposition. Les résultats obtenus avec deux niveaux de résolution ne sont pas dans tous les cas les meilleurs, mais bien souvent, parmi ceux de très bonne qualité. Si pour un niveau de résolution nous obtenons une segmentation de très bonne qualité alors l'apport d'un deuxième niveau de décomposition n'est pas significatif. Cependant, pour certaines textures complexes, le deuxième niveau de résolution permet alors d'améliorer les résultats. Enfin, nous avons testé pour l'ensemble des méthodes plusieurs types de régionalités (voisinage) avec le paramètre  $N = \{5, 7, 9\}$ . Nous pouvons alors conclure qu'il n'existe pas de régionalité qui soit adaptée pour tous types de textures. Ce paramètre doit être réglé de façon à avoir une visibilité suffisante des motifs d'une texture avec un voisinage large pour segmenter des macro-textures et plus restreint pour segmenter des micro-textures. Il faut noter cependant que la multirésolution peut apporter une partie de réponse à ce problème puisqu'elle permet d'avoir une description à la fois globale et locale d'une texture.

### 3.5 Quelques mots sur les temps de calcul et la normalisation des données

La table 3.12 présente les temps d'exécution utilisés par les méthodes GLCM 3D, HUF et LBP 3D, pour segmenter une image 3D contenant  $128^3$  voxels. L'ordinateur utilisé est équipé d'un processeur Intel Core 2 Duo E8400 3.0 GHz et de 3.50 Go de RAM. La durée d'exécution de ces méthodes d'analyse de textures dépend énormément des paramètres choisis. Par exemple, la méthode  $LBP_{26,1}^{riu2}$  affiche des temps de calcul raisonnables alors que les temps d'exécution de la méthode  $LBP_{218,3}^{riu2}$  sont extrêmement longs. Plus le nombre de vertex de la sphère LBP est important, plus la méthode LBP 3D est lente. Le point sensible de cette méthode est la fonction de calcul de l'homogénéité des motifs ( $U(LBP_{P',R})$ ) qui effectue des croissances de région sur les différents vertex d'une sphère LBP. La méthode GLCM 3D se révèle très rapide avec un paramètre de quantification  $q = 8$ , cependant lorsque le nombre de niveaux de gris considéré est plus important alors les temps d'exécution peuvent devenir excessifs. En augmentant le paramètre de quantification, la taille de la matrice de cooccurrence devient plus importante et il est donc plus long d'en extraire les caractéristiques. Les temps d'exécution de la méthode HUF dépendent du nombre de caractéristiques choisies ainsi que du nombre de résolutions utilisées. Les temps de calcul sont relativement faibles même lorsque trois niveaux de décompositions sont considérés (compris entre 1 et 2 minutes).

### 3.6. CONCLUSION

Méthodes	(a)	(b)	(c)	(d)	(e)
$LBP_{26,1}^{riu2}$ , N=5	0, 88	0, 60	2, 96	2, 36	30, 82
$LBP_{26,1}^{riu2}$ , N=7	0, 74	0, 50	<b>1, 18</b>	0, 95	21, 49
$LBP_{26,1}^{riu2}$ , N=9	2, 23	0, 72	1, 43	0, 97	20, 25
$LBP_{98,2}^{riu2}$ , N=5	1, 23	0, 78	3, 74	3, 32	31, 88
$LBP_{98,2}^{riu2}$ , N=7	1, 33	0, 51	2, 48	2, 35	20, 88
$LBP_{98,2}^{riu2}$ , N=9	6, 87	<b>0, 46</b>	2, 06	0, 76	19, 68
HUF, db2, $\beta = 1$ , N=5	0, 91	1, 73	8, 31	2, 07	27, 35
HUF, db2, $\beta = 1$ , N=7	<b>0, 71</b>	0, 60	8, 42	2, 00	16, 70
HUF, db2, $\beta = 1$ , N=9	1, 12	0, 50	2, 09	1, 04	16, 18
HUF, db2, $\beta = 2$ , N={5,7},	1, 30	0, 87	1, 87	<b>0, 72</b>	<b>12, 45</b>
HUF, haar, $\beta = 1$ , N=5	2, 52	1, 26	16, 78	2, 34	27, 82
HUF, haar, $\beta = 1$ , N=7	2, 00	1, 30	8, 26	2, 76	17, 31
HUF, haar, $\beta = 1$ , N=9	5, 96	2, 57	2, 60	1, 51	30, 32
HUF, haar, $\beta = 2$ , N={5,7}	4, 25	2, 39	9, 17	1, 98	14, 65
GLCM, $q = 8$ , $d = 1$ , N=5	0, 87	9, 75	17, 50	3, 40	36, 66
GLCM, $q = 8$ , $d = 1$ , N=7	1, 14	3, 95	3, 83	2, 60	31, 28
GLCM, $q = 8$ , $d = 1$ , N=9	1, 00	0, 87	9, 29	2, 99	32, 23
GLCM, $q = 8$ , $d = 2$ , N=5	1, 24	54, 16	21, 30	12, 33	29, 83
GLCM, $q = 8$ , $d = 2$ , N=7	4, 10	33, 91	13, 82	43, 08	32, 46
GLCM, $q = 8$ , $d = 2$ , N=9	18, 46	42, 33	22, 13	12, 34	33, 63

TAB. 3.9 – Evaluation de segmentations de textures solides contenant deux classes à partir de la mesure générique d'anomalie.

Dans sa version actuelle, toutes les caractéristiques de la méthode HUF ne sont pas comprises entre 0 et 1. Pour réaliser une segmentation optimale à l'aide de l'algorithme des K-means, il est alors nécessaire d'effectuer une étape de normalisation des données ou d'utiliser une distance appropriée. Nous avons choisi d'utiliser la distance de Mahalanobis qui demande la construction d'une matrice de covariance et permet ainsi de prendre en compte l'hétérogénéité des différentes caractéristiques. L'hétérogénéité des valeurs prises par nos descripteurs est plus difficile à gérer lorsqu'il s'agit de fournir à l'utilisateur une aide à l'interprétation : "Une valeur de granularité de 0,92 correspond-elle à une amplitude forte, faible ou moyenne?". Une solution envisageable serait d'effectuer un étalonnage sur des textures typiques pour déterminer les valeurs extrêmes (minimales et maximales) ce qui permettrait de borner l'ensemble des descripteurs HUF entre 0 et 1.

## 3.6 Conclusion

Dans le but de valider notre méthode HUF (*Human understandable features*), nous présentons, dans ce chapitre, des tests expérimentaux en classification et en segmentation sur des images de synthèse pour lesquelles nous disposons de vérités terrains. Pour cela, nous la comparons avec des méthodes très utilisées et connues dans la littérature : les matrices de cooccurrence d'Haralick (GLCM) [Haralick, 1979, Haralick *et al.*, 1973], la méthode des

### 3.6. CONCLUSION

Méthodes	(f)	(g)	(h)	(i)	(j)
$LBP_{26,1}^{riu2}$ , N=5	9, 76	6, 19	6, 71	29, 69	11, 18
$LBP_{26,1}^{riu2}$ , N=7	9, 72	5, 51	3, 01	15, 08	17, 31
$LBP_{26,1}^{riu2}$ , N=9	14, 07	<b>1, 57</b>	3, 21	39, 55	13, 73
$LBP_{98,2}^{riu2}$ , N=5	9, 26	13, 21	20, 62	21, 27	14, 14
$LBP_{98,2}^{riu2}$ , N=7	9, 80	25, 50	21, 33	<b>3, 45</b>	8, 88
$LBP_{98,2}^{riu2}$ , N=9	9, 51	1, 68	2, 61	14, 97	<b>7, 89</b>
HUF, db2, $\beta = 1$ , N=5	8, 10	23, 50	21, 76	8, 16	15, 82
HUF, db2, $\beta = 1$ , N=7	4, 84	7, 61	24, 29	8, 77	20, 80
HUF, db2, $\beta = 1$ , N=9	8, 48	5, 91	<b>2, 38</b>	9, 52	20, 37
HUF, db2, $\beta = 2$ , N={5,7}	6, 52	7, 64	6, 88	8, 60	15, 67
HUF, haar, $\beta = 1$ , N=5	8, 19	10, 00	26, 23	13, 72	25, 52
HUF, haar, $\beta = 1$ , N=7	<b>3, 90</b>	10, 02	23, 96	8, 48	24, 82
HUF, haar, $\beta = 1$ , N=9	9, 04	5, 84	8, 94	12, 07	22, 59
HUF, haar, $\beta = 2$ , N={5,7}	6, 90	7, 01	10, 70	9, 03	15, 61
GLCM, $q = 8$ , $d = 1$ , N=5	10, 27	10, 69	20, 13	47, 10	18, 51
GLCM, $q = 8$ , $d = 1$ , N=7	9, 11	9, 18	22, 06	29, 99	19, 51
GLCM, $q = 8$ , $d = 1$ , N=9	9, 75	7, 05	16, 85	21, 94	17, 01
GLCM, $q = 8$ , $d = 2$ , N=5	11, 79	14, 35	35, 53	65, 26	24, 61
GLCM, $q = 8$ , $d = 2$ , N=7	36, 31	17, 81	22, 04	25, 63	36, 27
GLCM, $q = 8$ , $d = 2$ , N=9	39, 44	15, 93	26, 68	39, 58	26, 08

TAB. 3.10 – Evaluation de segmentations de textures solides contenant trois classes à partir de la mesure générique d’anomalie.

motifs binaires (LBP) 2D [Ojala et Pietikäinen, 2002] et une extension 3D que nous avons proposé [Paulhac *et al.*, 2008]. Pour pouvoir effectuer ces tests, nous avons construit une base de données de textures solides contenant des images 3D en nombre et diversité suffisant pour mettre en place des évaluations significatives de classification et de segmentation. Cette base de données est en libre accès sur le web et il est donc possible pour un chercheur de l’utiliser pour valider une méthode en analyse de textures ou pour l’enrichir.

Durant les tests de classification, deux bases de test ont été utilisées : une première ne contenant que des textures volumétriques sans aucune transformation (normales) et une deuxième comprenant à la fois des textures normales et des textures bruitées. Sur la première base, les méthodes LBP 2D et 3D permettent d’obtenir les meilleurs résultats. Vient ensuite la méthode HUF suivie des caractéristiques d’Haralick. Cependant, sur la deuxième base de test, la méthode HUF dépasse les méthodes LBP 2D et 3D dont les taux de classification baissent fortement en présence de bruit. Notre méthode HUF se révèle donc moins sensible à certaines déformations comme le bruit ce qui prouve une robustesse plus large face à ce type de caractéristiques. En segmentation, la méthode HUF permet d’obtenir les meilleurs résultats si nous considérons l’ensemble des textures volumétriques considérées dans nos tests. La méthode LBP 3D permet elle aussi d’obtenir de bons résultats mais celle-ci est distancée par la méthode HUF, notamment sur les textures les plus complexes. Nous pouvons également constater qu’il est difficile de prédire une valeur de régionalité qui

### 3.6. CONCLUSION

Méthodes	(k)	(l)	(m)	(n)	(o)
$LBP_{26,1}^{riu2}$ , N=5	38,05	12,19	58,12	57,72	43,08
$LBP_{26,1}^{riu2}$ , N=7	40,27	15,27	53,08	47,10	27,92
$LBP_{26,1}^{riu2}$ , N=9	33,06	1,57	52,25	51,42	30,32
$LBP_{98,2}^{riu2}$ , N=5	39,01	13,21	43,36	51,09	44,26
$LBP_{98,2}^{riu2}$ , N=7	32,09	4,76	32,47	46,52	40,07
$LBP_{98,2}^{riu2}$ , N=9	22,41	16,41	42,02	48,51	28,18
HUF, db2, $\beta = 1$ , N=5	31,16	8,60	41,66	51,81	31,23
HUF, db2, $\beta = 1$ , N=7	30,77	9,88	26,35	40,22	20,47
HUF, db2, $\beta = 1$ , N=9	<b>19,12</b>	<b>1,14</b>	24,81	32,22	<b>10,19</b>
HUF, db2, $\beta = 2$ , N={5,7}	22,03	2,41	13,43	40,17	20,10
HUF, haar, $\beta = 1$ , N=5	40,23	10,56	34,50	59,80	34,35
HUF, haar, $\beta = 1$ , N=7	33,30	8,54	28,79	50,30	16,16
HUF, haar, $\beta = 1$ , N=9	30,54	4,43	<b>10,92</b>	<b>29,90</b>	26,34
HUF, haar, $\beta = 2$ , N={5,7}	20,02	3,36	15,44	40,34	17,75
GLCM, $q = 8$ , $d = 1$ , N=5	34,63	13,39	39,92	54,53	41,50
GLCM, $q = 8$ , $d = 1$ , N=7	38,80	12,59	46,18	49,98	34,46
GLCM, $q = 8$ , $d = 1$ , N=9	36,76	14,76	40,39	45,80	33,88
GLCM, $q = 8$ , $d = 2$ , N=5	43,30	19,25	32,25	61,31	46,40
GLCM, $q = 8$ , $d = 2$ , N=7	40,38	17,04	49,05	55,69	48,89
GLCM, $q = 8$ , $d = 2$ , N=9	41,77	15,75	43,00	57,89	46,27

TAB. 3.11 – Evaluation de segmentations de textures solides contenant quatre classes à partir de la mesure générique d’anomalie.

Méthode	temps d’exécution (en seconde)
HUF, db2, $\beta = 1$ , N=7	86,98
HUF, db2, $\beta = 2$ , N={5,7}	113,55
HUF, db2, $\beta = 3$ , N={3,5,7}	144,43
GLCM, $q = 8$ , $d = 1$ , N=7	68,19
GLCM, $q = 16$ , $d = 1$ , N=7	147,53
GLCM, $q = 32$ , $d = 1$ , N=7	579,26
$LBP_{26,1}^{riu2}$ , N=7	93,70
$LBP_{98,2}^{riu2}$ , N=7	437,72
$LBP_{218,3}^{riu2}$ , N=7	1143,46

TAB. 3.12 – Temps d’exécution des méthodes HUF, GLCM 3D et LBP 3D pour segmenter une image 3D de taille  $128^3$ .

soit efficace pour tous types de textures. Dans le cas d’une macro-texture, ce paramètre doit être assez large afin d’obtenir une visibilité suffisante concernant les motifs. Son réglage est moins problématique pour les micro-textures cependant une valeur trop importante réduirait la précision sur les frontières des régions à identifier. Enfin il est important de souligner l’importance de la multirésolution qui permet, comme nous pouvons le voir dans nos tests de classification, une amélioration significative des résultats.

### 3.6. CONCLUSION

---

Ce chapitre valide donc de manière quantitative les performances de notre méthode HUF tant en segmentation qu'en classification. Dans le chapitre suivant, nous intégrons nos caractéristiques dans une application médicale afin de segmenter des images échographiques 3D. Nous nous attachons alors à démontrer l'intérêt d'utiliser des caractéristiques qui soient compréhensibles par un utilisateur afin d'être à même de segmenter différents types de textures à l'aide d'un unique système.

### 3.6. CONCLUSION

---

## Chapitre 4

# Segmentation d'images échographiques 3D

Dans ce chapitre, nous appliquons les descripteurs de textures proposés dans cette thèse afin de produire des segmentations sur des images échographiques 3D de la peau. Nous avons pu travailler sur ce type d'images grâce au système d'échographie haute résolution équipé d'une sonde 3D développé par l'équipe 5 de l'UMR INSERM U390 - CNRS ERL3106 - Université François Rabelais de Tours en collaboration avec la Société Lyonnaise ATYS Medical. En terme d'application, le traitement des images échographiques de la peau peut permettre d'aider au dépistage de pathologies, comme le mélanome ou le carcinome basocellulaire, d'estimer l'incidence ou de suivre l'évolution d'un traitement. En ce qui concerne la valorisation, des industriels (éditeurs de logiciels ou constructeurs de sondes 3D) se sont intéressés à nos travaux dans le but de proposer de nouveaux outils de mesure de paramètres cutanés permettant d'évaluer les effets de produits cosmétiques.

Afin de détailler le contexte du travail développé dans ce chapitre, nous présentons brièvement les modalités d'acquisition des images échographiques traitées. Nous voyons ensuite un état de l'art détaillant les principales méthodes de segmentation habituellement appliquées à ce type d'images. Enfin, nous discutons les intérêts de notre proposition à travers la présentation du logiciel que nous avons mis en place en collaboration avec des spécialistes en échographie 3D et à travers une comparaison avec d'autres méthodes d'analyse de textures.

### 4.1 Caractéristiques et modes d'acquisition des images ultrasonores 3D

L'échographie est une technique d'imagerie très utilisée dans le domaine médical. En effet, les techniques ultrasonores présentent de nombreux avantages par rapport à d'autres méthodes comme la résonance magnétique (IRM), la tomographie à rayons X (CT) etc. Elles ne sont pas ionisantes (pas dangereuses pour les patients), le résultat est visualisé en temps réel avec un coût moins important qu'avec les autres techniques. Cependant,

elles sont opérateur-dépendant avec une interprétation complexe des images qui nécessite l'intervention de médecins spécialistes en échographie.

### 4.1.1 Sonde d'acquisition 3D

Une image tridimensionnelle s'acquiert par l'intermédiaire d'une sonde 3D permettant le balayage d'un faisceau acoustique de telle sorte à acquérir des échos sur un volume de  $16 \times 16 \times 8 \text{ mm}^3$ . Dans [Grégoire *et al.*, 2006], les méthodes de balayage utilisées en 2D et 3D sont décrites et détaillées. Concernant l'imagerie 2D, trois principaux modes de balayages sont présentés :

- Le balayage linéaire : celui-ci permet l'obtention d'images rectangulaires adaptées à l'exploration superficielle. Il présente cependant l'inconvénient d'être lent (phénomène de balourd).
- Le balayage sectoriel : ce type de balayage permet des vitesses plus importantes comparé à la méthode précédente. Cependant, l'image obtenue n'est pas rectangulaire et possède une angulation.
- Le balayage circulaire : L'avantage de ce type de balayage est qu'il est très simple à réaliser mais l'image obtenue a la forme d'un disque.

La combinaison d'un mode de balayage 2D à un autre, suivant un axe différent, permet d'obtenir un balayage 3D. Grâce à l'acquisition 3D, il devient alors possible de visualiser des plans de coupe non accessibles en 2D. Une acquisition 3D peut aussi être obtenue en déplaçant manuellement une sonde 2D suivant un axe perpendiculaire à l'axe de la sonde. Dans ce cas, il existe une perte de précision des mesures sur l'axe du déplacement manuel qui dépend de la dextérité de l'opérateur. L'utilisation d'une sonde 2D sur un portique est possible, mais cela reste souvent encombrant. Il est toutefois préférable d'utiliser une sonde 3D autonome, de poids et de taille faible, qui permet une acquisition de très bonne qualité. C'est ce type de sonde, aujourd'hui associé à l'appareil d'échographie DERMICUP d'*Atys medical*, que nous avons utilisé.

### 4.1.2 Images échographiques 2D et 3D

La segmentation des images ultrasonores est fortement influencée par la qualité des données fournies [Noble et Boukerroui, 2006]. En effet, celles-ci contiennent un certain nombre d'artefacts et de variations liées aux phénomènes de propagation des ultrasons qui compliquent le processus de segmentation. Nous pouvons citer le speckle, l'atténuation du signal, les bulles dans les produits de couplage ou la réflexion sur des interfaces obliques qui se traduit par l'absence de certaines frontières comme pour les vaisseaux sanguins. Il faut noter cependant un certain nombre d'améliorations concernant la résolution spatio-temporelle, les capteurs et la portabilité avec les appareils récents. Cela permet d'améliorer la qualité des informations et donc des acquisitions et des images à traiter [Noble et Boukerroui, 2006]. Le développement des techniques d'acquisition entraîne alors une émergence de l'intérêt d'utilisation des images ultrasonores. Il est même envisagé de pouvoir les utiliser dans le guidage d'intervention ainsi qu'en thérapie [Noble et Boukerroui, 2006]. Enfin, soulignons que l'échogénicité est primordiale dans l'analyse des images échographiques. Celle-ci représente l'habilité d'un tissu à créer un écho. A l'intérieur d'une image ultrasonore, les zones



#### 4.1. CARACTÉRISTIQUES ET MODES D'ACQUISITION DES IMAGES ULTRASONORES 3D

---

échogènes contiennent un grand nombre de motifs blancs. C'est la raison pour laquelle les spécialistes utilisent principalement l'échogénéité, qui correspond en fait à une information de textures, comme caractéristique visuelle, pour décrire les structures normales et pathologiques.

##### 4.1.3 Images ultrasonores de la peau




FIG. 4.1 – Exemple d'image 3D de la peau obtenue avec l'échographe 20 MHz DERMICUP (Atys Medical France)

Aujourd'hui, les fabricants proposent des appareils échographiques dont la résolution peut aller de  $100\ \mu\text{m}$  à  $30\ \mu\text{m}$  [Grégoire *et al.*, 2006]. Cela nécessite des fréquences ultrasonores comprises entre 20 MHz et 60 MHz. L'augmentation des fréquences ultrasonores permet une amélioration de la résolution, mais engendre une augmentation de l'atténuation des milieux d'explorations. Avec de telles résolutions, il est possible d'observer parfaitement la peau et particulièrement le derme dont l'épaisseur moyenne est comprise entre 1 et 2 mm. Il est aussi possible d'explorer une partie de l'hypoderme et particulièrement l'interface derme-hypoderme. En revanche, la résolution est insuffisante pour l'exploration de l'épiderme (figure 4.1) dont l'épaisseur, comprise entre 0.05 et 0.3 mm, nécessite l'utilisation de fréquences ultrasonores supérieures à 80 MHz. L'échographie de la peau permet la visualisation de tumeurs (mélanomes, carcinomes basocellulaires, kystes, nævus, etc.), de récurrences, de cicatrices et de pathologies inflammatoires. Même si la discrimination entre les différentes lésions n'est pas toujours évidente, l'échographie cutanée apporte une aide

précieuse au dépistage et au diagnostic en améliorant la précision. La possibilité de segmenter et de caractériser une lésion en 3D s'avère très utile pour établir une stratégie thérapeutique. L'échographie 3D de la peau n'est pas très répandue en raison d'un manque d'outils d'analyse d'images 3D. Avec une acquisition 3D, il est possible de mesurer des caractéristiques inaccessibles en 2D pour permettre, par exemple, le suivi dans le temps de l'évolution d'une structure ou d'une lésion, notamment en utilisant les mesures de volume.

## 4.2 Méthodes de segmentation classiques

La segmentation des images échographiques reste une problématique difficile à résoudre. En effet, ces images médicales présentent des artefacts caractéristiques comme des ombres, le speckle, des atténuations, des atténuations de frontière, etc., et il est parfois compliqué d'obtenir les résultats souhaités.

Dans [Noble et Boukerroui, 2006], les auteurs proposent un état de l'art complet sur la segmentation d'images ultrasonores en mode B et identifient les points essentiels pour réaliser une bonne segmentation de ces images. Parmi les techniques proposées, nous retrouvons des méthodes proposant de modéliser le bruit présent dans ces images [Levienaise-Obadia et Gee, 1999, Chen *et al.*, 2001, Boukerroui, 2003, Chen *et al.*, 2003, Yu et Aston, 2004, Slabaugh *et al.*, 2006, Bernard *et al.*, 2007, Saroul *et al.*, 2008, Lecellier, 2009], mais également des méthodes utilisant des caractéristiques de textures afin d'identifier les différentes régions en fonction de leur échogénéicité [Basset *et al.*, 1993, Valckx et Thijssen, 1997, Boukerroui *et al.*, 2001, Zhan et Shen, 2003, Sahiner *et al.*, 2004, Zhan et Shen, 2006, Lecellier, 2009]. Il est également possible d'ajouter des contraintes de forme pour aider et guider le processus de segmentation [Hill et Taylor, 1992, Hill *et al.*, 1993, Jacob *et al.*, 2002, Comaniciu *et al.*, 2004, Paragios *et al.*, 2005, Cheng et Foo, 2007]. Ces différentes approches sont décrites plus précisément dans les sections suivantes.

### 4.2.1 *A priori* sur le bruit

D'après [Lecellier, 2009], un modèle de bruit permet de guider une segmentation et peut être introduit de manière locale, mais également de manière globale. Les méthodes locales présentent l'avantage de se focaliser sur une zone de l'image et ne sont donc pas perturbées par les régions voisines de la zone d'intérêt [Levienaise-Obadia et Gee, 1999, Yu et Aston, 2004]. Les approches locales permettent une modélisation statistique du signal échographique moins fine et la plupart des auteurs préfèrent adopter la vision globale. Dans [Boukerroui, 2003], les auteurs essaient de coupler les informations locales et globales en se reposant sur le paradigme Bayésien. Très peu de chercheurs utilisent ce couplage d'informations et préfèrent donc tenir compte uniquement d'informations globales [Lecellier, 2009].

Plusieurs auteurs, comme [Chen *et al.*, 2001, Chen *et al.*, 2003], utilisent la distribution de Rayleigh pour modéliser le bruit de façon globale. Ceux-ci proposent au préalable de pré-segmenter l'image à l'aide de points d'intérêts. Plus récemment, une approche variationnelle basée sur une super-ellipse déformable et utilisant une énergie région basée sur la distribution de Rayleigh a été utilisée dans la segmentation de prostates à l'intérieur

d'image échographiques [Saroul *et al.*, 2008].

La loi de Rayleigh n'est pas la seule à avoir été utilisée dans la littérature pour modéliser le bruit et les distributions des niveaux de gris. Nous pouvons également citer la loi Gaussienne [Boukerroui *et al.*, 2001, Lin *et al.*, 2003], la distribution Gamma [Tao *et al.*, 2003], la distribution Beta [Marcos Martin-Fernández, 2003], la loi exponentielle [Paragios *et al.*, 2005], la loi Fisher-Tippett [Slabaugh *et al.*, 2006], ou la distribution gaussienne généralisée [Bernard *et al.*, 2007].

### 4.2.2 Utilisation de contraintes de forme

Dans [Noble et Boukerroui, 2006], les auteurs présentent une grande partie des méthodes permettant l'intégration de contraintes de forme. Celles-ci sont généralement intégrées à l'intérieur de modèles déformables et de contours actifs. L'utilisation d'un contour actif paramétrique permet d'imposer une forme à travers l'utilisation des paramètres internes au contour, comprenant notamment la continuité mais également la courbure. Cette méthode est simple à mettre en place mais reste très limitée car il est impossible de modéliser une forme précise à travers les termes de régularisation du modèle. Afin d'imposer une contrainte de forme, une deuxième méthode consiste à utiliser une forme paramétrique permettant d'obtenir une forme souhaitée. La méthode proposée dans [Pathak *et al.*, 2004] permet l'utilisation d'une contrainte de forme selon ce modèle. Afin d'imposer une contrainte de forme, une alternative connue consiste à utiliser un modèle de distribution de points [Cootes *et al.*, 1995]. Un modèle de distribution de points intégré dans une segmentation est connu sous le nom de modèle de forme actif. Ce type d'approche ne demande aucune paramétrisation concernant la forme, qui est définie par un ensemble d'apprentissage. Une extension de cette méthode, appelée modèle d'apparence actif, permet l'intégration d'informations supplémentaires sur les intensités ou les textures [Burkhardt et Neumann, 1998]. Afin d'obtenir une meilleure flexibilité sur les variations de forme, un modèle de forme actif a été intégré dans un modèle de contour actif implicite [Rousson *et al.*, 2004] et appliqué en échocardiographie dans [Paragios *et al.*, 2005]. Les contraintes de formes sont utilisées sur tout types d'organes, mais la plupart du temps dans des applications de segmentation du cœur [Hill et Taylor, 1992, Hill *et al.*, 1993, Jacob *et al.*, 2002, Comaniciu *et al.*, 2004, Cheng et Foo, 2007].

### 4.2.3 Analyse des textures

Dans [Noble et Boukerroui, 2006], les techniques d'analyse de textures sont décrites comme étant des méthodes très efficaces pour la classification ou la segmentation d'images échographiques. Une méthode classique, comme les matrices de cooccurrence d'Haralick [Haralick *et al.*, 1973, Haralick, 1979], permet d'obtenir de très bonnes performances dans un certain nombre d'applications [Basset *et al.*, 1993, Valckx et Thijssen, 1997]. Cependant, la plupart des auteurs proposent des méthodes de segmentation d'images échographiques 2D uniquement. Dans le domaine des textures, [Boukerroui *et al.*, 2001] proposent une méthode de segmentation multirésolution pour des données échographiques tri-dimensionnelles (2D+T, 3D) en utilisant l'intensité des niveaux de gris, les caractéris-

tiques de textures d'Haralick et des informations 3D de caractérisation de tissus à partir du spectre local de fréquence des signaux radio-fréquence. Leur conclusion est que l'utilisation de caractéristiques complémentaires permet d'obtenir une segmentation plus robuste. [Sahiner *et al.*, 2004] caractérisent des images échographiques 3D du sein. Pour cela, ils utilisent des modèles de contours actifs 2D et 3D pour une segmentation automatique. De cette segmentation, ils extraient des caractéristiques 3D de textures mais également des caractéristiques morphologiques. Dans leur étude, les résultats de classification des masses du sein malignes et bénignes sont très similaires à ceux des experts. [Zhan et Shen, 2003, Zhan et Shen, 2006] présentent un modèle déformable pour la segmentation d'images ultrasonores 3D de la prostate. Pour cela, ils calculent des caractéristiques de textures en utilisant deux bancs de filtres construits à partir de filtres de Gabor 2D et localisés dans les deux plans orthogonaux. L'utilisation d'un filtre de Gabor 3D demanderait des temps de calcul plus importants mais, en contrepartie, permettrait d'obtenir des informations plus riches sur les textures présentes dans ces images médicales.

Finalement, il semble que notre sélection de descripteurs concorde avec les techniques obtenant de bonnes performances sur les images échographiques. Cette constatation nous conforte donc dans la pertinence de nos choix et nous laisse espérer des résultats très intéressants. En effet, notre proposition devrait permettre d'augmenter l'interaction et donc l'utilisabilité des systèmes automatiques d'analyse de textures échographiques par des experts en ultrasons ou des médecins. Rappelons que notre proposition concerne les images 3D et que celles-ci semblent avoir un avenir prometteur à court terme. Concernant le mécanisme de segmentation, les contours actifs limitent la segmentation à une partie de l'image. Dans notre approche, nous adoptons une méthode de *clustering* permettant d'isoler l'ensemble des régions de l'image comprenant des caractéristiques de textures différentes.

### 4.3 Notre proposition

Pour ce travail, nous nous sommes contraint à mettre en place des caractéristiques de textures qualificatives compréhensibles par un être humain. Cette volonté est née à la fois de notre désir de collaborer avec les chercheurs de l'équipe 5 de l'UMR INSERM U390 - CNRS ERL3106 - Université François Rabelais de Tours spécialisé en échographie 3D haute résolution ainsi que de notre volonté de produire un système d'analyse de textures générique, robuste et facilement utilisable.

Un effort très important et de longue haleine a dû être produit aussi bien par nous que par les spécialistes en échographie pour établir une confiance et un vocabulaire commun. De nombreuses séances de discussion et de descriptions collaboratives de contenus de diverses images 3D ultrasonores (images de la peau, images buccales ou petit animal 2D et 3D) ont été nécessaires pour mettre en place des liens entre les terminologies propres à chacune des disciplines : échogénicité, anisotropie, cônes d'ombre, speckle, atténuation du signal d'un côté et régionalité, textons, composantes connexes, binarisation de l'autre. Par la suite, d'autres entretiens ont permis de cerner les régions d'intérêt à localiser dans les images (mélanomes, nævus, kyste, etc.). Enfin, la présentation du logiciel, de son mode de configuration, d'utilisation et des explications sur les segmentations produites ont également été nécessaires. Les travaux sur ce dernier point sont d'ailleurs encore en cours car les interfaces actuellement proposées ne permettent pas aux personnes non formées d'utiliser facilement

### 4.3. NOTRE PROPOSITION

toutes les fonctionnalités du logiciel. Une aide est donc encore aujourd’hui toujours nécessaire pour configurer les paramètres spécifiques au domaine de l’analyse d’images (régionalité, nombre de résolutions, nombre de classes). Il est à noter que les spécialistes ont très rapidement identifié l’intérêt de certaines caractéristiques de textures pour la séparation de certaines zones de la peau : l’échogénicité d’une zone peu être décrite principalement par des mesures de granularité sur les motifs 3D ; l’extraction d’un tendon demande d’exploiter des informations de directionnalité, etc. L’intérêt de chacun des attributs de textures proposé a été validé par les spécialistes en dermatologie et en échographie. Le tableau 4.1 présente une synthèse du travail de mise en correspondance entre nos attributs de textures et les caractéristiques propres à chaque pathologie ou organe nécessitant d’être isolé dans les images. Il n’était bien évidemment pas possible de prédire les valeurs prises par chaque attribut mais seulement de les quantifier qualitativement (faible :+, moyen :++, fort :+++).

Région	Description littérale	Attributs de textures
Naevus, Histiocytofibrome, Kyste, Mélanome, carcinome basocellulaire	Ces lésions sont présentes dans le derme et possèdent une échogénicité faible ou moyenne.	granularité :+, compacité :+++ , contraste :+, rugosité :+, régularité :++, directionnalité :+
Tendon	Il possède une échogénicité importante et régulièrement répartie avec une anisotropie forte.	granularité :+, compacité :+, contraste :++, rugosité :++, régularité :++, directionnalité :+++
Derme Normal	Dans cette zone, l’échogénicité est régulière.	granularité :+++ , compacité :+, contraste :++, rugosité :++, régularité :+, directionnalité :+
Hypoderme	Cette région de la peau est plus ou moins échogène selon les zones.	granularité :++, compacité :++, contraste :++, rugosité :++, régularité :+, directionnalité :+
Epiderme	La résolution n’est pas assez importante pour analyser l’épiderme. De plus il est similaire à la membrane de la sonde avec une forte échogénicité.	granularité :+, compacité :+, contraste :++, rugosité :+, régularité :++, directionnalité :+

TAB. 4.1 – Textures dans les images ultrasonores de la peau

#### 4.3.1 Architecture du système proposé et interactivité

L’architecture du système proposé se compose de trois modules principaux (figure 4.2). Le premier est un module de calcul de caractéristiques de textures exploitant des paramètres fournis par l’utilisateur. Les caractéristiques sont ensuite utilisées par le deuxième

module de segmentation. L'image segmentée est alors envoyée au module de visualisation 3D. Ce module permet à l'utilisateur de visualiser le résultat de la segmentation initiale qu'il est possible d'améliorer de manière interactive par un processus de fusion des régions 3D. Il est également possible de représenter ces régions à l'aide d'un maillage ou d'effectuer des mesures afin d'avoir des informations supplémentaires (volumes, mesures de distances, etc.).

Avant de lancer une segmentation, l'utilisateur doit sélectionner les caractéristiques qui lui semblent pertinentes afin de traiter l'image volumétrique chargée. Il doit également renseigner les paramètres supplémentaires de régionalité (définition du voisinage considéré autour d'un voxel) et le nombre de résolutions à considérer. Une interface graphique (figure 4.3) permet à l'utilisateur de définir ses choix. Les caractéristiques et paramètres ainsi que l'image volumétrique sont alors envoyés au module de calcul de caractéristiques. Pour chaque voxel de l'image, ce dernier calcul les attributs de textures sélectionnés en considérant la régionalité et le nombre de résolutions spécifié. Le module de segmentation prend ensuite le relais pour exploiter l'ensemble des vecteurs de caractéristiques calculés. En premier lieu, une sur-segmentation est effectuée à l'aide des K-means. Par défaut, un nombre important de classes est proposé ( $K = 20$ ) mais peut être modifié par l'utilisateur (figure 4.3). Une deuxième étape interactive de fusion permet à l'utilisateur d'affiner les résultats de segmentation. La fusion des classes est réalisée en utilisant une classification ascendante hiérarchique à l'intérieur de laquelle les deux régions les plus proches sont fusionnées à chaque étape (section 3.4.2.1). L'utilisateur peut ainsi choisir la segmentation qui convient le mieux à ses attentes. Le module de visualisation et de mesure peut ensuite être utilisé afin d'isoler et visualiser une région de l'image segmentée par l'intermédiaire d'un maillage (figure 4.7, 4.13). Il est également possible de calculer le volume des différentes régions isolées. La figure 4.2 résume ces différentes étapes en mettant en évidence les points d'intervention de l'utilisateur durant le processus d'analyse de l'image 3D.

#### 4.3.2 Résultats obtenus et comparaison aux autres méthodes

Afin d'évaluer notre système sur des images réelles, nous avons proposé notre prototype logiciel à des dermatologues et échographistes pour les aider à collecter des informations 3D sur un certain nombre de pathologies et d'organes.

Les tests effectués ont démontré la capacité du logiciel à isoler différents types de pathologies en fonction des choix de configuration effectués par l'utilisateur. De nombreuses démonstrations nous ont été demandées et certains médecins, et industriels, semblent intéressés et satisfaits par les résultats obtenus. Dans la suite, nous présentons des segmentations sur trois images échographiques différentes : l'image 4.5 contient un naevus, l'image 4.11 un histiocytofibrome et l'image 4.17 un tendon. D'autres exemples de segmentations sur ce type d'images sont présentées en annexe B. Sur les images 4.5 et 4.11, nous avons généré des segmentations à partir des 3 algorithmes utilisés dans le chapitre précédent avec notre méthode HUF, la méthode des motifs binaires LBP 3D et les matrices de cooccurrence d'Haralick GLCM 3D. Pour chaque méthode, nous présentons les images segmentées (figures 4.6, 4.8, 4.10, 4.12, 4.14 et 4.16) ainsi qu'une représentation sous forme de maillages des pathologies extraites lorsque la segmentation permet de les isoler (4.7, 4.9, 4.13 et 4.15). Concernant la méthode LBP 3D, les résultats de segmentation sont générés à partir




FIG. 4.2 – Schéma représentatif de l'utilisation de notre logiciel

de l'opérateur  $LBP_{26,1}^{riu2}$ . Les matrices de cooccurrence d'Haralick sont utilisées en considérant le paramètre de quantification  $q = 8$  et la distance entre deux voxels  $d = 1$ . Enfin, les résultats présentés pour la méthode HUF sont obtenus à partir de l'ondelette Daubechie (db2) et pour un seul niveau de décomposition. Sur l'image 4.17, les résultats de segmentation présentés sont obtenus à partir de la méthode HUF et ceci pour différents niveaux de décomposition. Pour l'ensemble de ces méthodes, nous avons choisi d'utiliser un paramètre de régionalité  $N = 7$  qui permet d'obtenir de bons résultats sur ce type d'images.

Afin d'effectuer la segmentation présentée à la figure 4.6 de l'image 4.5, les spécialistes en ultrasons ont choisi d'utiliser l'ensemble des caractéristiques de la méthode HUF excepté la directionnalité, puisqu'aucune zone de l'image ne présente de caractère anisotrope. D'après ces spécialistes, cette segmentation se révèle être de très bonne qualité puisqu'elle permet d'isoler l'ensemble du nævus (Figure 4.7). En comparaison, les matrices de cooccurrence d'Haralick ne permettent pas de l'isoler de façon aussi précise. D'après les spécialistes,

### 4.3. NOTRE PROPOSITION

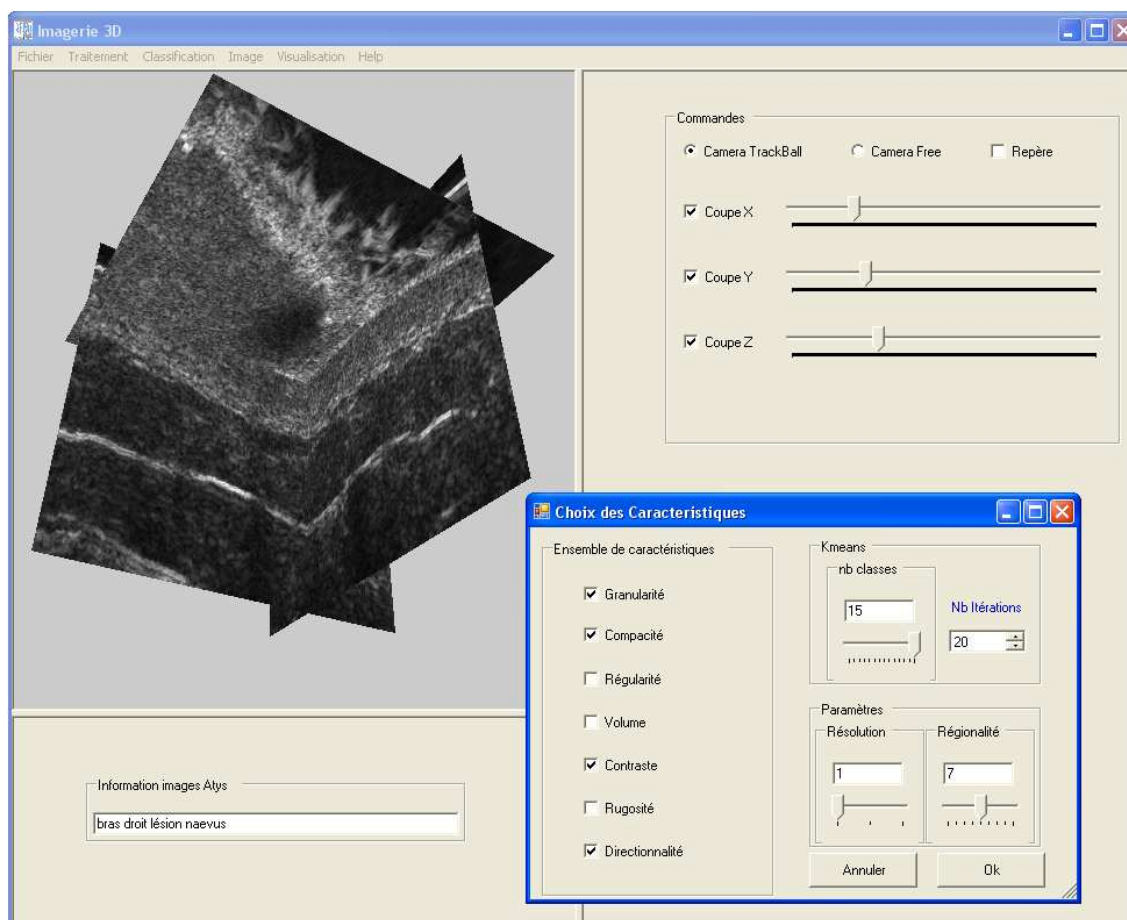


FIG. 4.3 – Interfaces du prototype logiciel mis en place pour la segmentation d'images échographiques 3D.

le nævus, que nous représentons par un maillage à la figure 4.9, n'est pas complet. Si nous regardons la segmentation présentée à la figure 4.10, nous pouvons remarquer que le nævus n'est pas identifié par la méthode LBP 3D. Les changements d'intensité constituent ici une information essentielle. Or, les méthodes LBP ont la propriété d'être invariantes à ce type de variation. De ce fait, les résultats obtenus avec la méthode LBP 3D sont peu satisfaisants. Si nous regardons la segmentation présentée figure 4.16 construite à partir de l'image ultrasonore 3D présentée figure 4.11, la méthode LBP 3D ne permet toujours pas la détection de l'histiocytofibrome. La méthode HUF est utilisée de la même manière que précédemment mais n'utilise pas la caractéristique de directionnalité. En effet, l'image 4.11 est du même type que l'image 4.5 et ne contient aucune direction privilégiée. Notre méthode permet d'obtenir une bonne segmentation (figures 4.12, 4.13) qui d'après les spécialistes en ultrasons se révèle de meilleure qualité par rapport à celle obtenue à partir des caractéristiques d'Haralick (figures 4.14, 4.15).

La figure 4.17(a) représente l'image ultrasonore 3D d'un tendon. A partir de la méthode HUF, nous présentons plusieurs images résultats : la figure 4.17(b) générée à partir de l'en-



## 4.4. CONCLUSION

---

semble des caractéristiques excepté la directionnalité, les figures 4.17(d), 4.17(e), 4.17(f) obtenues avec l'ensemble des caractéristiques. Un seul niveau de décomposition est considéré pour obtenir la segmentation 4.17(d), deux niveaux de décomposition pour la segmentation 4.17(e) et trois niveaux de décomposition pour la segmentation 4.17(f). Comme nous pouvons le voir sur les figures 4.17(b) et 4.17(c), il est impossible d'isoler le tendon sans l'attribut de directionnalité. En effet, nous avons vu à la table 4.1 que la propriété principale d'un tendon est sa forte anisotropie. En rajoutant la caractéristique de direction, et en utilisant une seule résolution, nous obtenons la segmentation figure 4.17(e) à partir de laquelle il devient possible d'isoler le tendon (4.17(g)). En augmentant le nombre de résolutions, les segmentations obtenues deviennent de meilleures qualités : avec deux résolutions le tendon est segmenté de façon plus uniforme (figure 4.17(h)) et avec trois résolutions nous obtenons une segmentation plus propre où seul le tendon est isolé (figure 4.17(i)). Pour les images 4.5 et 4.11, il n'est pas nécessaire d'utiliser plusieurs niveaux de décomposition car pour une unique résolution, les segmentations obtenues sont de très bonne qualité. L'apport de plusieurs résolutions n'est alors pas significatif.

Nous en concluons que notre approche permet de segmenter efficacement des régions d'intérêts intéressantes pour les dermatologues telles que les tumeurs ou bien les tendons. D'autres expériences ont démontré que notre méthode permet également d'isoler très facilement les différentes couches de la peau (Figure 4.4). Il est alors possible d'effectuer des mesures d'épaisseur ou de rugosité sur le derme ou l'hypoderme. Ces informations intéressent les industriels en cosmétique qui peuvent ainsi évaluer qualitativement et objectivement les effets d'un produit sur la peau.

## 4.4 Conclusion

D'un point de vue applicatif, notre méthode offre une interaction supérieure entre le praticien et la machine par rapport à toute autre méthode de la littérature. Nous avons proposé à des spécialistes en échographie d'utiliser et de réaliser des segmentations avec notre logiciel. Notre effort pour proposer des caractéristiques compréhensibles par un être humain rend plus facile l'utilisation de notre méthode mais également la sélection des caractéristiques importantes pour discriminer l'objet recherché du reste de l'image. Nous pouvons prendre comme exemple l'image du tendon, pour laquelle, la caractéristique de directionnalité est, à chaque fois, sélectionnée par l'opérateur. De plus, après discussion avec les médecins et échographistes, l'utilisation de caractéristiques compréhensibles présente un intérêt supplémentaire. La mesure des caractéristiques et l'analyse de leur évolution au cours du temps dans certaines zones précises de l'image échographique peut aider le médecin à déterminer le type de pathologie ou à suivre son évolution.

Actuellement, la sélection de nos caractéristiques se fait de façon binaire : si l'attribut est sélectionné alors celui-ci est utilisé, sinon il ne l'est pas. Il serait intéressant de pouvoir moduler la sélection en proposant un potentiel de participation, choisi par l'utilisateur, et ceci pour chaque attribut de textures.

Dans ce chapitre, nous avons présenté plusieurs segmentations sur des images ultrasonores 3D de la peau. La segmentation de ce type d'images permet notamment d'aider les médecins dans la mise en place d'un diagnostic afin d'établir une stratégie thérapeutique. Les entreprises en cosmétique sont également très intéressées puisque l'analyse des différentes

#### 4.4. CONCLUSION

---

couches de la peau leur permettrait de valider l'efficacité de certains produits.

Afin de donner une évaluation de nos descripteurs HUF, nous avons demandé à des spécialistes en ultrasons de générer des segmentations à partir de différentes méthodes d'analyse de textures (HUF, LBP 3D, GLCM 3D) et de comparer les images segmentées et les maillages obtenus. Notre méthode HUF permet d'obtenir de très bonnes segmentations qui se révèlent être de meilleure qualité en comparaison avec les algorithmes LBP 3D et GLCM 3D. Actuellement, les résultats sont uniquement évalués de façon qualitative par les praticiens. Produire une vérité terrain pour une image échographique 2D n'est pas très contraignant, mais sur des images 3D, cela devient plus complexe. En effet, il serait nécessaire de produire une vérité terrain pour chacune des coupes 2D de l'image ultrasonore 3D. Avec cet ensemble de vérités terrain 2D, il serait alors possible de générer une version 3D en rassemblant les coupes. Mais cette construction de chaque vérité terrain 2D serait extrêmement coûteuse en temps et les variabilités inter-opérateurs sont parfois importantes, ce qui rend ce type d'approche inutilisable pour l'instant. Cependant, il serait intéressant de discuter avec des spécialistes afin d'identifier et de proposer des métriques pour une évaluation non-supervisée. Il serait alors possible d'obtenir une évaluation quantitative et objective sur des images réelles.

Ces expérimentations avec les praticiens nous ont également permis de voir les points (encore nombreux) qui restent à améliorer dans le système proposé : outre le choix des caractéristiques (assez facile), le choix et le réglage des autres paramètres sont plus difficiles (régionalité, nombre de résolutions) et se fait souvent par tâtonnements successifs ou avec une aide de notre part. Les temps de calcul sur les images échographiques traitées ( $300^3$  voxels) sont encore longs et recommencer plusieurs fois une segmentation devient vite fastidieux. C'est pourquoi nous avons parfois généré les segmentations en offline et ajouté une fonctionnalité au logiciel pour permettre le rechargement direct de résultats pré-calculés. L'utilisation de notre logiciel devient alors beaucoup plus simple et conviviale. L'annexe B présente un autre ensemble de résultats produits à partir d'images échographiques 3D, montrant les capacités du logiciel qui intéresse actuellement différents acteurs du secteur de la santé et de la cosmétique (dermatologues, constructeurs de sondes, laboratoires en cosmétique, etc.).




FIG. 4.4 – Visualisation des différentes couches de la peau obtenues à partir d'une image segmentée.

#### 4.4. CONCLUSION

---




FIG. 4.5 – Image ultrasonore 3D de la peau contenant un nævus.




FIG. 4.6 – Segmentation de l'image figure 4.5 obtenue avec la méthode HUF




FIG. 4.7 – Maillage construit à partir de l'image segmentée figure 4.6 (méthode HUF).




FIG. 4.8 – Segmentation de l'image figure 4.5 obtenue avec la méthode GLCM 3D.

#### 4.4. CONCLUSION

---




FIG. 4.9 – Maillage construit à partir de l'image segmentée figure 4.8 (GLCM 3D).




FIG. 4.10 – Segmentation de l'image figure 4.5 obtenue avec la méthode LBP 3D.




FIG. 4.11 – Image ultrasonore 3D de la peau contenant un histiocytofibrome




FIG. 4.12 – Segmentation de l'image figure 4.11 obtenue avec la méthode HUF.

#### 4.4. CONCLUSION

---




FIG. 4.13 – Maillage construit à partir de l'image segmentée figure 4.12 (méthode HUF).




FIG. 4.14 – Segmentation de l'image figure 4.11 obtenue avec la méthode GLCM 3D.




FIG. 4.15 – Maillage construit à partir de l'image segmentée figure 4.14 (GLCM 3D).




FIG. 4.16 – Segmentation de l'image figure 4.11 obtenue avec la méthode LBP 3D.






FIG. 4.17 – Ensemble de segmentations d’une image échographique 3D avec la méthode HUF (localisation de tendons).

#### 4.4. CONCLUSION

---

# Conclusion

Dans ce mémoire de thèse, nous nous sommes intéressés à l'extraction de caractéristiques pour analyser les images texturées 3D, également connues sous le nom de textures solides ou textures volumétriques. Ainsi, nous avons proposé un ensemble de caractéristiques qualificatives, facilement compréhensibles par les êtres humains : la granularité, le contraste, le volume, la compacité, la régularité, la directionnalité et la rugosité. Pour établir cette liste de descripteurs de textures, nous nous sommes attaché à choisir des termes simples, génériques, complémentaires et fréquemment utilisés par l'homme pour décrire des textures volumétriques. Ces adjectifs permettent d'obtenir une certaine richesse dans la description des textures mais également de les caractériser de façon robuste.

Les méthodes de construction de ces dernières tirent partie de l'ensemble des travaux antérieurs effectués dans le domaine et dont nous avons discuté tout au long du chapitre état de l'art. Ainsi, les modes de calcul des descripteurs proposés combinent les méthodes fréquentielles d'analyse multirésolution avec la décomposition en ondelette discrète, mais également des méthodes géométriques et statistiques utilisant notamment la notion de composantes connexes 3D multi-niveaux. Une attention particulière a été portée sur le paramétrage des méthodes d'extraction des caractéristiques afin que celles-ci soient aisément exploitables. Un utilisateur, même non expert en vision par ordinateur, doit être capable d'adapter le système d'analyse pour traiter des objectifs différents. Actuellement, chacun des descripteurs proposés peut facilement être inhibé. Les paramètres de régionalité et de précision d'analyse (nombre de résolutions) doivent également être choisis. Le réglage de ces deux dernières valeurs est moins intuitif, il serait donc pertinent d'étudier comment apporter une aide à l'utilisateur pour ce choix. Ce mode de fonctionnement apporte une certaine souplesse qui garantit une généralité. Cette particularité différencie notre proposition des précédentes qui se limitent bien souvent au traitement d'une problématique bien spécifique. Nous avons également mené des expérimentations psychologiques afin de prouver la forte correspondance entre les caractérisations obtenues automatiquement et l'appréciation humaine des textures. Un autre point intéressant dans l'approche proposée concerne la possibilité offerte aux utilisateurs de produire automatiquement une caractérisation quantitative précise d'une région sélectionnée à l'intérieur d'une texture volumétrique et de suivre son évolution au cours du temps.

Afin de valider notre méthode de caractérisation de textures HUF (*Human understandable features*), nous avons réalisé des tests expérimentaux en classification et en segmentation sur des images de synthèse pour lesquelles nous disposons de vérités terrain. Faute de bases existantes, nous avons construit une base de textures volumétriques, aujourd'hui

disponible sur le web en libre accès. Nous avons alors pu établir une comparaison avec des méthodes d'analyse de textures standards reconnues comme performantes : les matrices de cooccurrence des niveaux de gris d'Haralick (GLCM 3D), qui constituent une référence en analyse des textures, et la méthode des motifs binaires (LBP) qui permet d'obtenir des taux de reconnaissance élevés en 2D et que nous avons étendu à la 3D. Cette extension correspond par ailleurs à une autre de nos contributions. Il nous a alors été possible de situer notre méthode d'un point de vue quantitatif par rapport à d'autres travaux de la littérature.

Que ce soit en classification ou en segmentation, la méthode HUF offre de très bonnes performances qui prouvent la robustesse et la fiabilité de notre approche. Durant les tests de classification établis, notre méthode obtient les meilleurs taux de reconnaissance sur la base de test la plus complexe (introduction de variations dans les textures solides à reconnaître). Ce résultat prouve la généralité de notre approche ainsi que sa robustesse puisque ces conditions se rapprochent finalement beaucoup d'un cadre applicatif réel.

Sur l'ensemble des segmentations générées à partir de textures relativement simples, la méthode LBP 3D obtient de très bons résultats qui restent proches de ceux obtenus avec la méthode HUF. En revanche, sur certaines textures plus complexes, la méthode LBP 3D est surpassée par la méthode HUF. En effet, la méthode HUF fournit de bons résultats sur l'ensemble des textures volumétriques, même dans le cas de textures très complexes où les résultats de segmentation sont très bons en comparaison aux méthodes GLCM 3D et LBP 3D. Pour chacune des méthodes d'analyse, nous avons testé plusieurs cas de régionalité. Ce paramètre est une contrainte non-négligeable dans bon nombre de méthodes d'analyse d'images. Il doit être réglé de façon à avoir une vision suffisante des motifs composant une texture avec un voisinage large pour permettre la segmentation de macro-textures et plus restreint pour la segmentation de micro-textures. Enfin, il faut noter l'importance de la multirésolution, qui, dans certains cas, améliore considérablement les résultats.

Nos objectifs initiaux nous ont amené à construire un système dédié à la segmentation d'images ultrasonores 3D. A cette fin, nous avons utilisé nos descripteurs pour caractériser le contenu d'images échographiques de la peau. Une fois les descripteurs sélectionnés par l'utilisateur, les calculs sont effectués puis un algorithme de clustering (K-means) produit une première sur-segmentation de l'image. Celle-ci peut ensuite être retravaillée par l'utilisateur (fusion de régions voisines) afin de présenter une visualisation sous forme de maillage 3D de la (des) région(s) d'intérêt recherchée(s).

Pour chacune des méthodes d'analyse testée (HUF, GLCM 3D, LBP 3D), des spécialistes en ultrasons ont segmenté plusieurs images ultrasonores grâce au logiciel développé durant nos travaux. Ils ont pu comparer, de façon qualitative, les segmentations ainsi générées. Leur conclusion est que notre méthode HUF permet d'obtenir de très bonnes segmentations qui se révèlent être de meilleure qualité en comparaison des autres méthodes LBP 3D et GLCM 3D. De plus, notre méthode offre de meilleures possibilités d'interaction entre le praticien et la machine par rapport aux autres méthodes testées. En effet, la sélection des caractéristiques pertinentes pour isoler les zones d'intérêt recherchées du reste de l'image se révèle beaucoup plus simple avec la méthode HUF qu'avec la méthode GLCM 3D. L'étape de sélection n'est pas considérée avec l'algorithme LBP 3D puisque celui-ci caractérise une texture à partir de l'occurrence des motifs extraits. Enfin, nous avons mis en avant l'intérêt

## CONCLUSION

---

de la multirésolution, qui, dans certaines problématiques complexes, comme l'extraction d'un tendon, permet d'améliorer de façon significative les résultats.

D'un point de vue applicatif, nous avons souligné dans ce manuscrit quelques aspects pouvant être améliorés. Même si le choix des caractéristiques de textures de notre méthode est assez simple, le réglage de paramètres comme la régionalité et le nombre de résolutions sont plus complexes à effectuer. Le choix du nombre de résolutions pourrait se faire en fonction de la complexité des images à traiter et en fonction de leur taille. Ces critères restent cependant très subjectifs et ne permettraient pas de mettre en place un système totalement automatique. Le problème du paramètre de régionalité reste encore ouvert dans le domaine du traitement d'image. Certains auteurs ont proposé des méthodes pour déterminer automatiquement un voisinage optimal mais celles-ci restent dédiées à un type d'image particulier [Jan et Hsueh, 1998].

Une autre perspective concerne l'ajout d'un module supplémentaire au système de segmentation afin de pouvoir exploiter des connaissances *a priori* (atlas, informations topologiques, morphologiques, etc.). Une piste serait de construire un graphe d'adjacence de région 3D après la phase de sur-segmentation. Il serait ensuite comparé aux connaissances *a priori* pour produire une nouvelle segmentation plus conforme au contenu supposé de l'image. Une interaction utilisateur forte à ce niveau est également envisageable.

Une amélioration devra être également apportée sur les temps de calcul qui restent pour l'instant perturbants pour l'utilisateur. Nous avons déjà indiqué qu'une piste était de produire les calculs de caractéristiques en temps caché (offline) pour l'utilisateur (pendant l'exploration d'autres zones par exemple). Cet aspect se rapproche des considérations liées à l'interface Homme-Machine du logiciel et à l'ergonomie. De longues heures d'échange et de collaboration avec les divers acteurs intéressés par notre prototype seront encore nécessaires avant la production d'un système en adéquation complète avec leurs besoins.

Concernant l'évaluation de la qualité des segmentations obtenues à partir d'images ultrasonores 3D, il est possible d'envisager un certain nombre de perspectives. Actuellement, les résultats sont uniquement évalués de façon qualitative par les praticiens à travers des comparaisons visuelles de segmentations obtenues avec différentes méthodes. Dans ce manuscrit, nous avons déjà souligné les difficultés de générer une vérité terrain 3D avec des temps de construction considérables et des problèmes de précision non-négligeables. Il serait donc intéressant de discuter avec des dermatologues et spécialistes en ultrasons afin d'identifier et de proposer des métriques pour une évaluation non-supervisée.

A travers de nombreuses expérimentations, nous avons prouvé les intérêts ainsi que les performances de notre système. Bien que très satisfaisants, les résultats produits restent encore loin de ceux obtenus par le système visuel humain. L'exploration de pistes visant à obtenir des caractéristiques plus fiables, avec un niveau de précision plus proche de l'œil humain reste donc envisageable.

## CONCLUSION

---

# Annexes





## Annexe A

# Attributs de textures d'Haralick

A partir d'une matrice de cooccurrence d'Haralick  $P$  de taille  $n^2$ , nous pouvons calculer les caractéristiques suivantes qui sont le plus classiquement utilisées :

Average :

$$\sum_{i=1}^n \sum_{j=1}^n iP(i, j) \quad (\text{A.1})$$

Variance :

$$\sum_{i=1}^n \sum_{j=1}^n (i - Moy)^2 P(i, j) \quad (\text{A.2})$$

Maximum probability :

$$\max[P(i, j)] \quad (\text{A.3})$$

Angular Second Moment :

$$\sum_{i=1}^n \sum_{j=1}^n P(i, j)^2 \quad (\text{A.4})$$

Texture contrast :

$$\sum_{i=1}^n \sum_{j=1}^n |i - j| P(i, j) \quad (\text{A.5})$$

Correlation :

$$\frac{\sum_{i=1}^n \sum_{j=1}^n (i - \mu_x)(j - \mu_y) P(i, j)}{\sigma_x \sigma_y} \quad (\text{A.6})$$

Entropy :

$$\sum_{i=1}^n \sum_{j=1}^n P(i, j) \log(P(i, j)) \quad (\text{A.7})$$

Homogeneity :

$$\sum_{i=1}^n \sum_{j=1}^n \frac{P(i, j)}{1 + (i - j)^2} \quad (\text{A.8})$$

Contrast :

$$\sum_{i=1}^n i^2 P_{x-y}(i) \quad (\text{A.9})$$

Sum Average :

$$\sum_{i=1}^{2n} i P_{x+y}(i) \quad (\text{A.10})$$

Sum Entropy :

$$- \sum_{i=1}^{2n} P_{x+y}(i) \log(P_{x+y}(i)) \quad (\text{A.11})$$

Difference Entropy :

$$- \sum_{i=1}^n P_{x-y}(i) \log(P_{x-y}(i)) \quad (\text{A.12})$$

Information measure of correlation 1 :

$$\frac{HXY - HXY1}{\max(HX, HY)} \quad (\text{A.13})$$

Information measure of correlation 2 :

$$\sqrt{1 - \exp(-2(HXY2 - HXY))} \quad (\text{A.14})$$

Pour pouvoir calculer les caractéristiques précédentes, il est nécessaire de définir les statistiques suivantes :

$$HX = - \sum_{i=1}^n P_x(i) \log(P_x(i))$$

$$HY = - \sum_{i=1}^n P_y(i) \log(P_y(i))$$

$$HXY = \sum_{i=1}^n \sum_{j=1}^n P(i, j) \log(P(i, j))$$

$$HXY1 = - \sum_{i=1}^n \sum_{j=1}^n P(i, j) \log(P_x(i)P_y(j))$$

$$HXY1 = - \sum_{i=1}^n \sum_{j=1}^n P_x(i)P_y(j) \log(P_x(i)P_y(j))$$

$$P_x(i) = \sum_{j=1}^n P(i, j)$$

$$P_y(j) = \sum_{i=1}^n P(i, j)$$

$$P_{x+y}(i) = \sum_{i+j=q} P(i, j), \quad q = 2, 3, \dots, 2k$$

$$P_{|x-y|}(i) = \sum_{i+j=q} P(i, j), \quad q = 0, 1, \dots, k-1$$

$$\mu_x = \sum_{i=1}^n \sum_{j=1}^n iP(i, j)$$

$$\mu_y = \sum_{i=1}^n \sum_{j=1}^n jP(i, j)$$



## Annexe B

### Exemple de segmentation d'images ultrasonores de la peau




FIG. B.1 – Image ultrasonore 3D de la peau contenant un nævus.




FIG. B.2 – Segmentation de l'image figure B.1 obtenue avec la méthode HUF.




FIG. B.3 – Maillage construit à partir de l'image segmentée figure B.2 (méthode HUF).




FIG. B.4 – Image ultrasonore 3D de la peau contenant un histiocytofibrome.




FIG. B.5 – Segmentation de l'image figure B.4 obtenue avec la méthode HUF.




FIG. B.6 – Maillage construit à partir de l'image segmentée figure B.5 (méthode HUF).




FIG. B.7 – Image ultrasonore 3D de la peau contenant un mélanome.



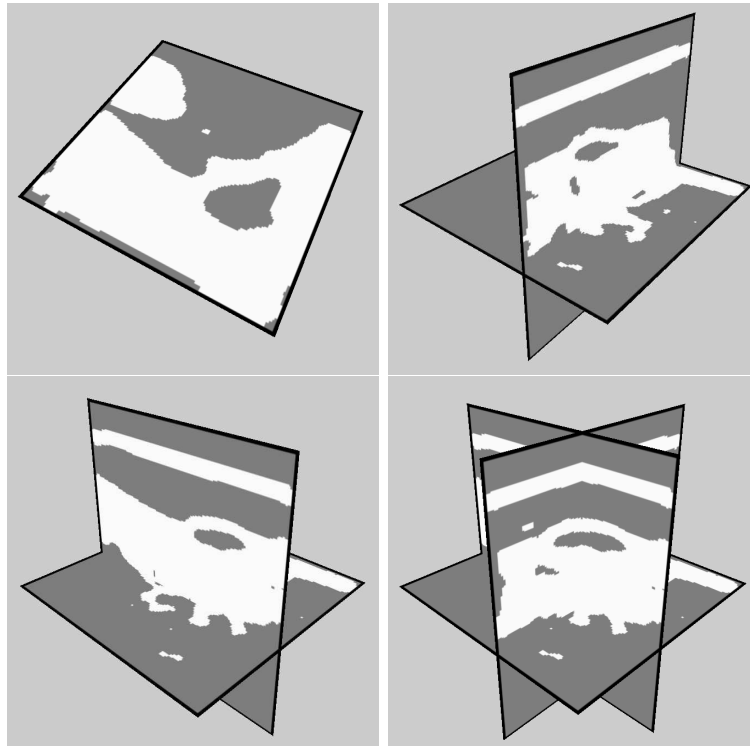


FIG. B.8 – Segmentation de l'image figure B.7 obtenue avec la méthode HUF.




FIG. B.9 – Maillage construit à partir de l'image segmentée figure B.8 (méthode HUF).

EXEMPLE DE SEGMENTATION D'IMAGES ULTRASONORES DE LA PEAU

## Annexe C

# Principaux composants de la DTD utilisée dans la construction de la base de textures solides

<!ELEMENT Image3D (Author,(SolidTexture+))>

<!ELEMENT Author (# PCDATA)>

<!ELEMENT SolidTexture (Packaging,Name,  
SynthesisType,Properties,Distortion)>

---

<!ELEMENT Packaging (Type,Size,Location,  
Rotation)>

...

---

<!ELEMENT Name (# PCDATA)>

---

<!ELEMENT SynthesisType (# PCDATA)>

---

<!ELEMENT Properties ((TextureModuleName)|  
(Pattern,Size,GrayLevel,PatternTexture)|(Texture2D))>

<!ELEMENT TextureModuleName (#PCDATA)>

<!ELEMENT Pattern (PatternNumber,  
PatternShape)>

...

## PRINCIPAUX COMPOSANTS DE LA DTD UTILISÉE DANS LA CONSTRUCTION DE LA BASE DE TEXTURE SOLIDE

---

< !ELEMENT Size (Radius1Min,Radius2Min,  
Radius3Min,Radius1Max,Radius2Max,Radius3Max)>

...

< !ELEMENT GrayLevel (GrayLevelMin,  
GrayLevelMax)>

...

< !ELEMENT PatternTexture (InnerTexture,  
OuterTexture)>

...

< !ELEMENT Texture2D (Name,PlanNumber)>

...

---

< !ELEMENT Distortion (GaussianSmooth,  
GaussianNoise,SubSampling,Rotation)>

...

---

## Annexe D

# Questionnaire sur le classement de textures volumétriques

A l'intérieur de ce questionnaire, nous demandons de classer différentes textures volumétriques (domaine 3D) et ceci pour chacune des caractéristiques de textures proposées : granularité, compacité, volume, rugosité, régularité, contraste, directionnalité (définitions ci-dessous). Le classement se fera de manière décroissante en ordonnant de la plus rugueuse à la plus lisse, de la plus régulière à la plus irrégulière etc. Les textures à classer sont visibles page 2 et une lettre est attribuée à chacune d'elles (a,b,c etc.). La finalité de cette expérience est de comparer, pour chacune des caractéristiques de textures, les résultats de ce questionnaire (perception humaine) avec des mesures informatiques.

### Définition des caractéristiques de textures utilisées :

**Granularité** : Qualité ou propriété de ce qui est granulaire. Une surface granulaire se compose de petits éléments. Par analogie, une texture granulaire est une texture composée de petits motifs. Mesure de la taille et du nombre de motifs élémentaires composant une texture. Elle permet de définir si une texture est plutôt fine ou grossière.

#### Information de formes :

- **La compacité** : Cette mesure décrit la géométrie des motifs d'une texture permettant de déterminer s'ils ont une forme plutôt compacte ou une forme plutôt allongée.
- **Le volume** : Ce descripteur mesure l'espace 2D ou 3D occupé par les motifs d'une texture solide.

**La rugosité** : Une texture rugueuse est une surface ou un volume qui présente des aspérités (surface inégale, raboteuse au toucher).


**La régularité** : Elle permet de mesurer le caractère répétitif d'une texture.

**Le contraste** : Il peut être défini comme le rapport entre les parties les plus foncées et les parties les plus claires d'une image. Mesurer le contraste revient à évaluer la dispersion des niveaux de gris dans une image.


**Directionnalité** : Mesure la forte ou faible présence d'une direction privilégiée.

QUESTIONNAIRE SUR LE CLASSEMENT DE TEXTURES VOLUMÉTRIQUES


---




(a)




(b)




(c)




(d)




(e)




(f)




(g)




(h)




(i)



(j)



(k)



(l)

## QUESTIONNAIRE SUR LE CLASSEMENT DE TEXTURES VOLUMÉTRIQUES

---

### Classement par caractéristique :

---

Exemple avec la caractéristique beauté (On classe dans l'ordre décroissant de la plus belle à la moins belle) :

Beauté : j - g - h - i - k - a - b - c - d - e - f - l

---

Granularité :

Compacité :

Volume :

Rugosité :

Régularité :

Contraste :

Directionnalité :

QUESTIONNAIRE SUR LE CLASSEMENT DE TEXTURES VOLUMÉTRIQUES



# Bibliographie

- [Ahoen *et al.*, 2006] AHOEN, T., HADID, A. et PIETIKÄINEN, M. (2006). Face description with local binary patterns : Application to face recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28:2037–2041.
- [Al-Janobi, 2001] AL-JANOBI, A. (2001). Performance evaluation of cross-diagonal texture matrix method of texture analysis. *Pattern Recognition*, 34:171–180.
- [Al-Kindi *et al.*, 1992] AL-KINDI, G., BAUL, R. et GILL, K. (1992). An application of machine vision in the automated inspection of engineering surfaces. *International journal of production research*, 30:241–253.
- [Aldasoro et Bhalerao, 2007] ALDASORO, C. C. R. et BHALERAO, A. (2007). Volumetric texture segmentation by discriminant feature selection and multiresolution classification. *IEEE Transactions on Medical Imaging*, 26:1–14.
- [Amadasun et King, 1989] AMADASUN, M. et KING, R. (1989). Texture features corresponding to textural properties. *IEEE Transactions on Systems, Man, and Cybernetics*, 19(5):1264–1274.
- [Arivazhagan et Ganesan, 2003] ARIVAZHAGAN, S. et GANESAN, L. (2003). Texture classification using wavelet transform. *Pattern Recognition Letters*, 24:1513–1521.
- [Aydin *et al.*, 1996] AYDIN, T., YEMEZ, Y., ANARIM, E. et SANKUR, B. (1996). Multidirectional and multiscale edge detection via m-band wavelet transform. *IEEE Transactions on Image Processing*, 5(9):1370–1376.
- [Basset *et al.*, 1993] BASSET, O., SUN, Z., MESTAS, J. et GIMENEZ, G. (1993). Texture analysis of ultrasonic images of the prostate by means of co-occurrence matrices. *Ultrasonic Imaging*, 15:218–237.
- [Bernard *et al.*, 2007] BERNARD, O., TOUIL, B., GELAS, A., PROST, R. et FRIBOULET, D. (2007). Segmentation of myocardial regions in echocardiography using the statistics of the radio-frequency signal. In *FIHM '07 : Proceedings of International Conference on Functional Imaging and Modeling of the Heart*.
- [Bernasconi *et al.*, 2001] BERNASCONI, A., ANTEL, S. B., COLLINS, D. L., BERNASCONI, N., OLIVIER, A., DUBEAU, F., PIKE, G. B., ANDERMANN, F. et ARNOLD, D. L. (2001). Texture analysis and morphological processing of magnetic resonance imaging assist detection of focal cortical dysplasia in extra-temporal partial epilepsy. *Annals of Neurology*, 49:770–775.
- [Besag, 1974] BESAG, J. (1974). Spatial interaction and the statistical analysis of lattice system. *Journal of the Royal Statistical Society*, 36(2):192–236.

- [Besag, 1986] BESAG, J. (1986). On the statistical analysis of dirty pictures. *Journal of the Royal Statistical Society*, 48:259–302.
- [Bigun, 1994] BIGUN, J. (1994). Speed frequency and orientation tuned 3d gabor filter banks and their design. In *ICPR '94 : Proceedings of the International Conference on Pattern Recognition*, pages 184–187.
- [Borah et al., 2007] BORAH, S., HINES, E. et BHUYAN, M. (2007). Wavelet transform based image texture analysis for size estimation applied to the sorting of tea granules. *Journal of Food Engineering*, 79:629–639.
- [Borgatti, 1994] BORGATTI, S. P. (1994). How to explain hierarchical clustering. *Connections*, 17:78–80.
- [Boukerroui, 2003] BOUKERROUI, D. (2003). Segmentation of ultrasound images : Multi-resolution 2d and 3d algorithms based on global and local statistics. *Pattern Recognition Letters*, 24:779–790.
- [Boukerroui et al., 2001] BOUKERROUI, D., BASSET, O., BASKURT, A. et GIMENEZ, G. (2001). A multiparametric and multiresolution segmentation algorithm of 3-d ultrasonic data. In *TUFFC '01 : Proceedings of the IEEE transactions on ultrasonics, ferroelectrics, and frequency control*.
- [Bovik et al., 1990] BOVIK, A., CLARK, M. et GEISLER, W. (1990). Multichannel texture analysis using localized spatial filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12:55–73.
- [Bracewell, 1986] BRACEWELL, R. (1986). *The Fourier Transform and its Applications*. McGraw-Hill.
- [Brady, 2003] BRADY, K. (2003). *A probabilistic framework for adaptive texture description*. Thèse de doctorat, Université de Nice-Sophia antipolis.
- [Bres, 1994] BRES (1994). *Contributions à la quantification des critères de transparence et d'anisotropie par une approche globale*. Thèse de doctorat, LIRIS Université de Lyon.
- [Brodatz, 1966] BRODATZ, P. (1966). *Textures : A Photographic Album for Artists and Designer*. Dover Pub.
- [Burkhardt et Neumann, 1998] BURKHARDT, H. et NEUMANN, B. (1998). Active appearance models. In *ECCV '98 : Proceedings of the European Conference on Computer Vision*.
- [Caenen et Gool, 2004] CAENEN, G. et GOOL, L. V. (2004). Maximum response filters for texture analysis. In *CVPRW '04 : Proceedings of the Computer Vision and Pattern Recognition Workshop*.
- [Cardoso et Corte-Real, 2005] CARDOSO, J. S. et CORTE-REAL, L. (2005). Toward a generic evaluation of image segmentation. *IEEE Transactions on Image Processing*, 14(11):1773–1782.
- [Caron et al., 2007] CARON, Y., MAKRIS, P. et VINCENT, N. (2007). Use of power law models in detecting region of interest. *Pattern Recognition*, 40:2521–2529.
- [Caselles et al., 1997] CASELLES, V., KIMMEL, R. et SAPIRO, G. (1997). Geodesic active contours. *International Journal of Computer Vision*, 22:61–79.

- [Chabrier *et al.*, 2008] CHABRIER, S., LAURENT, H., ROSENBERGER, C. et EMILE, B. (2008). Comparative study of contour detection evaluation criteria based on dissimilarity measures. *EURASIP Journal on Image and Video Processing*, 2008:13 pages.
- [Chan *et al.*, 2002] CHAN, T. F., SANDBERG, B. Y. et VESE, L. A. (2002). Active contours without edges for vector-valued images. *Journal of Visual Communication and Image Representation*, 11:130–141.
- [Chang et Lin, 2001] CHANG, C.-C. et LIN, C.-J. (2001). *LIBSVM : a library for support vector machines*. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [Chang et Kuo, 1993] CHANG, T. et KUO, C. C. J. (1993). Texture analysis and classification with tree-structured wavelet transform. *IEEE Transactions on Image Processing*, 2(4):429–441.
- [Chassery et Montanvert, 1991] CHASSERY, J.-M. et MONTANVERT, A. (1991). *Géométrie discrète en analyse d'images*.
- [Chellappa et Chatterjee, 1985] CHELLAPPA, R. et CHATTERJEE, S. (1985). Classification of textures using gaussian markov random fields. *IEEE Transactions on acoustic speech and signal processing*, 33:959–963.
- [Chellappa et Jain, 1993] CHELLAPPA, R. et JAIN, A. K. (1993). *Markov Random Fields Theory and Application*. Academic Press.
- [Chen et Chen, 1999] CHEN, C.-C. et CHEN, C.-C. (1999). Filtering methods for texture discrimination. *Pattern Recognition Letters*, 20:783–790.
- [Chen *et al.*, 2003] CHEN, C. M., LU, H. H. S. et CHEN, Y. L. (2003). A discrete region competition approach incorporating weak edge enhancement for ultrasound image segmentation. *Pattern Recognition Letters*, 24:693–704.
- [Chen *et al.*, 2000] CHEN, J., SATO, Y. et TAMURA, S. (2000). Orientation space filtering for multiple line segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22:417–429.
- [Chen et Murphy, 2004] CHEN, X. et MURPHY, R. F. (2004). Robust classification of subcellular location patterns in high resolution 3d fluorescence microscope images. In *EMBS'04 : Proceedings of the International Conference on Engineering in Medicine and Biology Society*, numéro 1-5.
- [Chen *et al.*, 2001] CHEN, Y., THIRUVENKADAM, S., TAGARE, H., HUANG, F., D. WILSON et GEISER, E. (2001). On the incorporation of shape priors into geometric active contours. In *IEEE Workshop on Variational and Level Set Methods in Computer Vision*, volume 1, pages 145–152.
- [Cheng et Foo, 2007] CHENG, J. et FOO, S. (2007). Boundary detection in echocardiographic images using markovian level set method. *IEICE Transactions on Information and Systems*, 90:1292–1300.
- [Chetverikov, 1995] CHETVERIKOV, D. (1995). Pattern orientation and texture symmetry. In *ICCAIP'95 : Proceedings of the 6th International Conference on Computer Analysis of Images and Patterns*.
- [Chitre et Dhawan, 1999] CHITRE, Y. et DHAWAN, A. (1999). M-band wavelet discrimination of natural textures. *Pattern Recognition*, 32:773–789.

- [Clarke, 1986] CLARKE, K. (1986). Computation of the fractal dimension of topographic surfaces using the triangular prism surface area method. *Computers and Geosciences*, 12(5):713–722.
- [Clausi et Jernigan, 1996] CLAUSI, D. et JERNIGAN, M. (1996). Towards a novel approach for texture segmentation of sar sea ice imagery. *In Proceedings of the 26th International Symposium on Remote Sensing of Environment and 18th Annual Symposium of the Canadian Remote Sensing Society*.
- [Clausi et Jernigan, 2000] CLAUSI, D. et JERNIGAN, M. (2000). Designing gabor filters for optimal texture separability. *Pattern Recognition*, 33:1835–1849.
- [Coggins, 1983] COGGINS, J. M. (1983). *A Framework for Texture Analysis Based on Spatial Filtering*. Thèse de doctorat, Michigan State University.
- [Cohen et Cooper, 1987] COHEN, F. S. et COOPER, D. B. (1987). Simple parallel hierarchical and relaxation algorithms for segmenting non causal markovian random fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(2):195–219.
- [Coifman et Wickerhauser, 1992] COIFMAN, R. R. et WICKERHAUSER, M. V. (1992). Entropy-based algorithms for best basis selection. *IEEE Transactions on Information Theory*, 38(2):713–718.
- [Coleman et Andrews, 1979] COLEMAN, G. et ANDREWS, H. (1979). Image segmentation by clustering. *In Proceedings of the IEEE*, pages 773–785.
- [Comaniciu *et al.*, 2004] COMANICIU, D., ZHOU, X. et KRISHNAN, S. (2004). Robust real-time myocardial border tracking for echocardiography : An information fusion approach. *IEEE Transactions on Medical Imaging*, 23:849–860.
- [Comer et Delp, 1999] COMER, M. L. et DELP, E. J. (1999). Segmentation of textured images using a multiresolution gaussian autoregressive model. *IEEE Transactions on Image Processing*, 8(3):408–420.
- [Cootes *et al.*, 1995] COOTES, T. F., TAYLOR, C. J., COOPER, D. H. et GRAHAM, J. (1995). Active shape models-their training and application. *Computer Vision and Image Understanding*, 61:38–59.
- [Coquerez et Phillip, 1995] COQUEREZ, J. et PHILLIP, S. (1995). *Analyse d’images : filtrage et segmentation*. Masson.
- [Coroyer, 1996] COROYER, C. (1996). *Apport des corrélations d’ordre élevé à l’analyse de textures non-gaussiennes*. Thèse de doctorat, Université Cergy-Pontoise.
- [Coster et Chermant, 1989] COSTER, M. et CHERMAND, J. L. (1989). *Precis d’Analyse d’Images*. CNRS.
- [Cross et Jain, 1983] CROSS, G. R. et JAIN, A. K. (1983). Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 5:25–39.
- [Cuba et Dana, 2004] CUBA, O. et DANA, K. (2004). 3d texture recognition using bidirectional feature histograms. *International Journal of Computer Vision*, 59(1):33–60.
- [Descombes *et al.*, 1999] DESCOMBES, X., SIGELLE, M. et PRÊTEUX, F. (1999). Estimating gaussian markov random field parameters in a non-stationary framework : Application to remote sensing imaging. *IEEE Transactions on Image Processing*, 8(4):490–503.

- [Dubuc *et al.*, 1989] DUBUC, B., ZUCKER, S., TRICOT, C., QUINIOU, J. et WEHBI, D. (1989). Evaluating the fractal dimension of surfaces. *Proceedings of the royal society of London*, 425:113–127.
- [Duda et Hart, 1972] DUDA, R. O. et HART, P. E. (1972). Use of the hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1):11–15.
- [Eglin, 1998] EGLIN, V. (1998). *Contribution à la structuration fonctionnelle des documents imprimés*. Thèse de doctorat, LIRIS.
- [Farrokhnia et Jain, 1991] FARROKHANIA, F. et JAIN, A. (1991). A multi-channel filtering approach to texture segmentation. In *CVPR '91 : Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*.
- [Fauzi et Lewis, 2003] FAUZI, M. F. et LEWIS, P. H. (2003). A fully unsupervised texture segmentation algorithm. In *BMVC '03 : Proceedings of the British Machine Vision Conference*.
- [Fawcett, 2006] FAWCETT, T. (2006). An introduction to roc analysis. *Pattern Recognition Letters*, 27:861–874.
- [Fernandez *et al.*, 2000] FERNANDEZ, M., MAVILIO, A. et TEJERA, M. (2000). Texture segmentation of a 3d seismic section with wavelet transform and gabor filters. In *ICPR '00 : Proceedings of the international Conference on Pattern Recognition*, volume 3, pages 354–357, Barcelona, Spain.
- [Ferri *et al.*, 2008] FERRI, C., ORALLO, J. H. et MODROIU, R. (2008). An experimental comparison of performance measures for classification. *Pattern Recognition Letters*.
- [Fogel et Sagi, 1989] FOGEL, I. et SAGI, D. (1989). Gabor filters as texture discriminator. *Biological Cybernetics*, 61(2):103–113.
- [François *et al.*, 2003] FRANÇOIS, R., FABLET, R. et BARILLOT, C. (2003). Robust statistical registration of 3d ultrasound images using texture information. In *ICIP '03 : Proceedings of the international Conference on Image Processing*, volume 1.
- [Fu, 1982] FU, K. S. (1982). *Syntactic Pattern Recognition and Applications*. Prentice-Hall.
- [Gabor, 1946] GABOR, D. (1946). Theory of communication. *IEE*, 93(3):429–457.
- [Gagalowicz, 1983] GAGALOWICZ, A. P. (1983). *Vers un modèle de texture*. Thèse de doctorat, Université Pierre et Marie Curie, Paris VI.
- [Geman et Geman, 1984] GEMAN, S. et GEMAN, D. (1984). Stochastic relaxation, gibbs distribution, and the bayesian restoration of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(6):721–741.
- [Germain, 2007] GERMAIN, C. (2007). Analyse d'images et de textures orientées appliquée à la caractérisation de matériaux et à la télédétection.
- [Ghoneim *et al.*, 2003] GHONEIM, D. M., TOUSSAINT, G., CONSTANS, J. M. et de CERTAINES, J. D. (2003). Three dimensional texture analysis in mri : a preliminary evaluation in gliomas. *Magnetic Resonance Imaging*, 21:983–987.
- [Gool *et al.*, 1985] GOOL, L. J. V., DEWAELE, P. et OOSTERLINCK, A. (1985). Texture analysis anno 1983. *Computer Vision, Graphics, and Image Processing*, 29(3):336–357.

- [Goyal *et al.*, 1994a] GOYAL, R., GOH, W., MITAL, D. et CHAN, K. (1994a). Invariant element compactness for texture classification. *In ICARCV '94 : Proceedings of the International Conference on Automation, Robotics and Computer Vision.*
- [Goyal *et al.*, 1994b] GOYAL, R., GOH, W., MITAL, D. et CHAN, K. (1994b). A translation rotation and scale invariant texture analysis technique based on structural properties. *In ICAT '94 : Proceedings of the Third International Conference on Automation Technology.*
- [Goyal *et al.*, 1995] GOYAL, R., GOH, W., MITAL, D. et CHAN, K. (1995). Scale and rotation invariant texture analysis based on structural property. *In IECON '95 : Proceedings of the International Conference on Industrial Electronics, Control, and Instrumentation.*
- [Granlund et Knutsson, 1995] GRANLUND, G. H. et KNUTSSON, H. (1995). *Signal Processing for Computer Vision.* Kluwer Academic Publishers. ISBN 0-7923-9530-1.
- [Grégoire *et al.*, 2006] GRÉGOIRE, J.-M., SERRIÈRE, S., GEORGESCO, G., JAMET, F., BLEUZEN, A., OSSANT, F., LEVASSORT, F., TRANQUART, F. et PATAT, F. (2006). Techniques et applications de l'échographie haute résolution non invasive. *Journal de Radiologie*, 87:1920–1936.
- [Guedon *et al.*, 1995] GUEDON, J., BARBA, D. et BURGER, N. (1995). Psychovisual image coding via an exact discrete radon transform. *In SPIE '95 : proceedings of the international conference of the Society of Photo-Optical Instrumentation Engineers*, volume 2501, pages 562–572.
- [Guo *et al.*, 2009] GUO, Z., LEIZHANG et DAVIDZHANG (2009). Rotation invariant texture classification using lbp variance (lbpv) with global matching. *Pattern Recognition.*
- [Gusfield, 2002] GUSFIELD, D. (2002). Partition-distance : A problem and class of perfect graphs arising in clustering. *Information Processing Letters*, 82(9):159–164.
- [Haralick, 1979] HARALICK, R. M. (1979). Statistical and structural approaches to textures. *Proceedings of the IEEE*, 67(5):786–804.
- [Haralick *et al.*, 1973] HARALICK, R. M., SHANMUGAM, K. et DINSTEN, I. (1973). Texture features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610–621.
- [He et Wang, 1991] HE, D.-C. et WANG, L. (1991). Texture features based on texture spectrum. *Pattern Recognition*, 24:391–399.
- [He *et al.*, 2004] HE, Y., LUO, Y. et HU, D. (2004). Unsupervised texture segmentation via applying geodesic active regions to gaborian feature space. *World Academy of Science, Engineering and Technology*, 2:272–275.
- [Higgins et Wakeley, 1994] HIGGINS, W. E. et WAKELEY, J. (1994). Texture segmentation using 2d gabor elementary functions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16:130–149.
- [Hill et Taylor, 1992] HILL, A. et TAYLOR, C. (1992). Model-based image interpretation using genetic algorithms. *In BMVC '92 : Proceedings of the British Machine Vision Conference*, volume 10, pages 295–300.
- [Hill *et al.*, 1993] HILL, A., THORNHAM, A. et TAYLOR, C. J. (1993). Model-based interpretation of 3d medical images. *In BMVC '93 : Proceedings of the British Machine Vision Conference.*

- [Hill *et al.*, 2002] HILL, P. R., CANAGARAJAH, C. N. et BULL, D. R. (2002). Texture gradient based watershed transform. *In ICASSP '02 : Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume 4, pages 3381–3384.
- [IP et Lam, 1994] IP, H. H. S. et LAM, S. W. C. (1994). Using an octree-based rag in hyper-irregular pyramid segmentation of texture volume. *In IAPR '94 : Proceedings of the IAPR Workshop on Machine Vision Applications*, pages 259–262, Kawasaki, Japan.
- [Ising, 1925] ISING, E. (1925). Beitrag zur theory des ferromagnetisms. *Zeitschrift fur Physik*, 31:253–258.
- [Jacob *et al.*, 2002] JACOB, G., NOBLE, J., BEHRENBRUCH, C., KELION, A. et BANNING, A. (2002). A shape-space-based approach to tracking myocardial borders and quantifying regional left-ventricular function applied in echocardiography. *IEEE Transactions on Medical Imaging*, 21:226–238.
- [Jafari-Khouzani *et al.*, 2004] JAFARI-KHOUZANI, K., SOLTANIAN-ZADEH, H., ELISEVICH, K. et PATEL, S. (2004). Comparison of 2d and 3d wavelet features for tle lateralization. *In Proceedings of the SPIE*, volume 5369.
- [Jain et Farrokhnia, 1990] JAIN, A. K. et FARROKHANIA, F. (1990). Unsupervised texture segmentation using gabor filters. *In ICSMC '90 : Proceedings of the IEEE international Conference on Systems, Man and Cybernetics*, volume 24, pages 1167–1186.
- [Jan et Hsueh, 1998] JAN, S.-R. et HSUEH, Y.-C. (1998). Window-size determination for granulometrical structural texture classification. *Pattern Recognition Letters*, 19:439–446.
- [Jeannane, 1995] JEANNANE, R. (1995). *Modélisation fractale de textures : Application à l'analyse de l'architecture osseuse*. Thèse de doctorat, Université d'Orléan.
- [Julesz, 1962] JULESZ, B. (1962). Visual pattern recognition. *IEEE Transactions on Information Theory*, 8.
- [Julesz, 1971] JULESZ, B. (1971). *Foundations of Cyclopean Perception*. The University of Chicago Press.
- [Jung, 2006] JUNG, C. R. (2006). Combining wavelets and watersheds for robust multiscale image segmentation. *Image and Vision Computing*, 25(1):24–33.
- [Kass et Witkin, 1987] KASS, M. et WITKIN, A. (1987). Analyzing oriented patterns. *Computer Vision, Graphics, and Image Processing*, 37:362–385.
- [Kaufman et Rousseeuw, 1990] KAUFMAN, L. et ROUSSEEUW, P. J. (1990). *Finding Groups in Data : An Introduction to Cluster Analysis*. John Wiley & Sons.
- [Keller *et al.*, 1989] KELLER, J. M., CHEN, S. et CROWNOVER, R. (1989). Texture description and segmentation through fractal geometry. *Computer Vision, Graphics, and Image Processing*, 45:150–166.
- [Kim et Kang, 2007] KIM, S. C. et KANG, T. J. (2007). Texture classification and segmentation using wavelet packet frame and gaussian mixture model. *Pattern Recognition*, 40:1207–1221.
- [Knutsson et Granlund, 1983] KNUTSSON, H. et GRANLUND, G. H. (1983). Texture analysis using two-dimensional quadrature filters. *In CAPAIDM '83 : IEEE Computer Society Workshop on Computer Architecture for Pattern Analysis and Image Database Management*.

- [Kopf *et al.*, 2007] KOPF, J., FU, C.-W., COHEN-OR, D., DEUSSEN, O., LISCHINSKI, D. et WONG, T.-T. (2007). Solid texture synthesis from 2d exemplars. *In SIGGRAPH '07 : Proceedings of the 34th International Conference on Computer Graphics and Interactive Techniques*.
- [Kovalev *et al.*, 2001] KOVALEV, V., KRUGGEL, F., GERTZ, H. et von CRAMON, D. (2001). Three-dimensional texture analysis of mri brain datasets. *IEEE Transactions on Medical Imaging*, 20(5):424–433.
- [Kovalev *et al.*, 2003a] KOVALEV, V., KRUGGEL, F. et von CRAMON, D. (2003a). Gender and age effects in structural brain asymmetry as measured by mri texture analysis. *NeuroImage*, 19:895–905.
- [Kovalev et Petrou, 1996] KOVALEV, V. et PETROU, M. (1996). Multidimensional cooccurrence matrices for object recognition and matching. *Graphical Models and Image Processing*, 58(3):187–197.
- [Kovalev *et al.*, 2003b] KOVALEV, V., PETROU, M. et SUCKLING, J. (2003b). Detection of structural differences between the brains of schizophrenic patients and controls. *Psychiatry Research : NeuroImaging*, 124(3):177–189.
- [Kovalev *et al.*, 1999] KOVALEV, V. A., PETROU, M. et BONDAR, Y. S. (1999). Texture anisotropy in 3d images. *IEEE Transactions on Image Processing*, 8:346–360.
- [Kreutz *et al.*, 1996] KREUTZ, M., VÖLPEL, B. et JANSSEN, H. (1996). Scale-invariant image recognition based on higher order autocorrelation features. *Pattern Recognition*, 29(1):19–26.
- [Krishnamachari et Chellappa, 1997] KRISHNAMACHARI, S. et CHELLAPPA, R. (1997). Multiresolution gauss-markov random field models for texture segmentation. *IEEE Transactions on Image Processing*, 6(2):251–267.
- [Kurita *et al.*, 1992] KURITA, T., OTSU, N. et SATO, T. (1992). A face recognition method using higher order local autocorrelation and multivariate analysis. *In ICPR '92 : Proceedings of the International Conference on Pattern Recognition*, volume 2, pages 213–216.
- [Laine et Fan, 1993] LAINE, A. et FAN, J. (1993). Textures classification by wavelet packets signatures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15:1186–1191.
- [Laine et Fan, 1996] LAINE, A. et FAN, J. (1996). Frame representations for texture segmentation. *IEEE Transactions on Image Processing*, 5:771–780.
- [Lang *et al.*, 1991] LANG, Z., SCARBERRY, R., ZHANG, Z., SHAO, W. et SUN, X. (1991). A texture-based direct 3d segmentation system for confocal scanningfluorescence microscopic images. *In SSST '91 : Proceedings of the Twenty-Third Southeastern Symposium on System Theory*, pages 472–476.
- [Laws, 1980a] LAWS, K. (1980a). Rapid texture identification. *In IPMG '80 : Proceedings of the International Conference on Image Processing for Missile Guidance*, pages 376–380.
- [Laws, 1980b] LAWS, K. (1980b). *Textured image segmentation*. Electrical engineering, University of Southern California.



- [Lecellier, 2009] LECELLIER, F. (2009). *Les contours actifs basés région avec a priori de bruit, de texture et de forme : Application à l'échocardiographie*. Thèse de doctorat, Université de CAEN.
- [Lehmann et al., 2001] LEHMANN, T., BREDNO, J. et SPITZER, K. (2001). Texture-adaptive active contour models. *In ICAPR '01 : Proceedings of the International Conference on Advances in Pattern Recognition*.
- [Leung et Malik, 2001] LEUNG, T. et MALIK, J. (2001). Representing and recognizing the visual appearance of materials using three-dimensional textons. *International Journal of Computer Vision*, 43(1):29–44.
- [Levienaise-Obadia et Gee, 1999] LEVIENAISE-OBADIA, B. et GEE, A. (1999). Adaptive segmentation of ultrasound images. *Image and Vision Computing*, 17(8):583–588.
- [Lewis, 1984] LEWIS, J.-P. (1984). Texture synthesis for digital painting. *SIGGRAPH Computer Graphics*, 18(3):245–252.
- [Li et al., 2003] LI, S., KWOKA, J. T., ZHUA, H. et WANG, Y. (2003). Texture classification using the support vector machines. *Pattern Recognition*, 36:2883–2893.
- [Li et Shawe-Taylor, 2005] LI, S. et SHAWE-TAYLOR, J. (2005). Comparison and fusion of multiresolution features for texture classification. *Pattern Recognition Letters*, 26:633–638.
- [Li, 1995] LI, S. Z. (1995). *Markov Random Field Modeling in Computer Vision*. Springer.
- [Li, 2001] LI, S. Z. (2001). *Markov Random Field Modeling in Image Analysis*. Springer.
- [Liapis et al., 1998] LIAPIS, S., ALVERTOS, N. et TZIRITAS, G. (1998). Unsupervised texture segmentation using discrete wavelet frames. *In ESPC '98 : Proceedings of the European Signal Processing Conference*.
- [Liapis et al., 2004] LIAPIS, S., SIFAKIS, E. et TZIRITAS, G. (2004). Colour and texture segmentation using wavelet frame analysis, deterministic relaxation, and fast marching algorithms. *Journal of Visual Communication and Image Representation*, 15:1–26.
- [Lin et al., 1997] LIN, H.-C., WANG, L.-L. et YANG, S.-N. (1997). Extracting periodicity of a regular texture based on autocorrelation functions. *Pattern Recognition Letters*, 18:433–443.
- [Lin et al., 2003] LIN, N., YU, W. et DUNCAN, J. (2003). Combinative multi-scale level set framework for echocardiographic image segmentation. *Medical Image Analysis*, 7:529–537.
- [Lopes et Betrouni, 2009] LOPES, R. et BETROUNI, N. (2009). Fractal and multifractal analysis : A review. *Medical Image Analysis*, 13:634–649.
- [Luk et Huynh, 1987] LUK, F. et HUYNH, V. (1987). A vision system for in-process surface quality assessment. *In Proceedings of the Vision'87 SME conference*.
- [Luo et Savakis, 2001] LUO, J. et SAVAKIS, A. E. (2001). Self-supervised texture segmentation using complementary types of features. *Pattern Recognition*, 34:2071–2082.
- [Lyvers et Mitchell, 1988] LYVERS, E. et MITCHELL, O. (1988). Precision edge contrast and orientation estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10:927–937.

- [Mallat, 1989] MALLAT, S. G. (1989). A theory for multiresolution signal decomposition : the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11:674–693.
- [Malpica *et al.*, 2003] MALPICA, N., ORTUÑO, J. E. et SANTOS, A. (2003). A multichannel watershed-based algorithm for supervised texture segmentation. *Pattern Recognition Letters*, 24:1545–1554.
- [Mandelbrot, 1977] MANDELBROT, B. B. (1977). *Fractals, Forms, Chance and Dimension*. Freeman and company.
- [Mandelbrot, 1983] MANDELBROT, B. B. (1983). *The Fractal Geometry of Nature*. Freeman.
- [Manian et Vasquez, 1998] MANIAN, V. et VASQUEZ, R. (1998). Scaled and rotated texture classification using a class of basis functions. *Pattern Recognition*, 31:1937–1948.
- [Marcos Martin-Fernández, 2003] MARCOS MARTIN-FERNÁNDEZ, C. A.-L. (2003). An approach for contour detection of human kidneys from ultrasound images using markov random fields and active contours. *Medical Image Analysis*, 9:1–23.
- [Martin *et al.*, 2006] MARTIN, A., LAANAYA, H. et ARNOLD-BOS, A. (2006). Evaluation for uncertain image classification and segmentation. *Pattern Recognition*, 39(11):1987–1995.
- [Medioni et Yasumoto, 1984] MEDIONI, G. et YASUMOTO, Y. (1984). A note on using the fractal dimension for segmentation. In *WCVRC '84 : Proceedings of the workshop on Computer Vision : Representation and Control, Annapolis*, pages 25–30.
- [Mital *et al.*, 1994] MITAL, D., GOH, W., CHAN, K. et GOYAL, R. (1994). A translation rotation and scale invariant texture analysis technique based on image granularity. In *ISRM '94 : Proceedings of the Fifth International Symposium on Robotics and Manufacturing*.
- [Mosquera *et al.*, 1992] MOSQUERA, A., CABELLO, D., CARREIRA, M. et PENEDO, M. (1992). A fractal-based approach to texture segmentation. In *ICIPA '92 : Proceedings of the International Conference on Image Processing and its Application*.
- [Muneeswaran *et al.*, 2005] MUNEESSWARAN, K., GANESAN, L., ARUMUGAM, S. et SOUNDAR, K. R. (2005). Texture classification with combined rotation and scale invariant wavelet features. *Pattern Recognition*, 38:1495–1506.
- [Myint et Lam, 2005] MYINT, S. W. et LAM, N. (2005). A study of lacunarity-based texture analysis approaches to improve urban image classification. *Computers, environment and urban systems*, 29(5):501–523.
- [Neyret, 1995] NEYRET, F. (1995). A general and multiscale model for volumetric textures. In DAVIS, W. A. et PRUSINKIEWICZ, P., éditeurs : *GI '95 : Proceedings of Graphics Interface*, pages 83–91. Canadian Information Processing Society, Canadian Human-Computer Communications Society. ISBN 0-9695338-4-5.
- [Ng et Han, 1994] NG, R. T. et HAN, J. (1994). Efficient and effective clustering methods for spatial data mining. In *VLDB '94 : Proceedings of the International Conference on Very Large Data Bases*.
- [Niblack, 1986] NIBLACK, W. (1986). *An Introduction to Digital Image Processing*. Prentice Hall.

- [Noble et Boukerroui, 2006] NOBLE, J. A. et BOUKERROUI, D. (2006). Ultrasound image segmentation : A survey. *IEEE Transactions on Medical Imaging*, 25(8):987–1010.
- [Novianto *et al.*, 2003] NOVIANTO, S., SUZUKI, Y. et MAEDA, J. (2003). Near optimum estimation of local fractal dimension for image segmentation. *Pattern Recognition Letters*, 24:365–374.
- [Ojala *et al.*, 1996] OJALA, T., PIETIKAINEN, M. et HARWOOD, D. (1996). A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29(1):51–59.
- [Ojala et Pietikäinen, 2002] OJALA, T. et PIETIKÄINEN, M. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24:971–987.
- [Ojala *et al.*, 2001] OJALA, T., PIETIKÄINEN, M. et MÄENPÄÄ, T. (2001). A generalized local binary pattern operator for multiresolution gray scale and rotation invariant texture classification. In *ICAPR '01 : Proceedings of the International Conference on Advances in Pattern Recognition*, pages 397–406.
- [Otsu et Kurita, 1988] OTSU, N. et KURITA, T. (1988). A new scheme for practical flexible and intelligent vision systems. In *IAPR '88 : Proceedings of the IAPR Workshop on Computer Vision*, pages 431–435.
- [Paragios et Deriche, 1999] PARAGIOS, N. et DERICHE, R. (1999). Geodesic active contours for supervised texture segmentation. In *CVPR '99 : Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*.
- [Paragios *et al.*, 2005] PARAGIOS, N., JOLLY, M.-P., TARON, M. et RAMARAJ, R. (2005). Active shape models and segmentation of the left ventricle in echocardiography. In *Scale-Space '05 : Proceedings of the International conference on Scale Space and PDE Methods in Computer Vision*.
- [Pathak *et al.*, 2004] PATHAK, L. G., HAYNOR, S., CHO, D. et KIM, P. Y. (2004). Parametric shape modeling using deformable superellipses for prostate segmentation. *IEEE Transactions on Medical Imaging*, 23:340–349.
- [Paulhac *et al.*, 2008] PAULHAC, L., MAKRIS, P. et RAMEL, J.-Y. (2008). Comparison between 2d and 3d local binary pattern methods for characterisation of three-dimensional textures. In *ICIAR '08 : Proceedings of the 5th International Conference in Image Analysis and Recognition*.
- [Paulhac *et al.*, 2009] PAULHAC, L., MAKRIS, P. et RAMEL, J.-Y. (2009). A solid texture database for segmentation and classification experiments. In *VISSAPP '09 : Proceedings of the Fourth International Conference on Computer Vision Theory and Applications*.
- [Peleg *et al.*, 1984] PELEG, S., NAOR, J., HARTLEY, R. et AVNIR, D. (1984). Multiple resolution texture analysis and classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(4):518–523.
- [Pentland, 1984] PENTLAND, A. (1984). Fractal based description of natural scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6:661–674.
- [Perlin, 1985] PERLIN, K. (1985). An image synthesizer. In *SIGGRAPH '85 : Proceedings of the 12th International Conference on Computer Graphics and Interactive Techniques*, pages 287–296. ACM.

- [Petrou et Sevilla, 2006] PETROU, M. et SEVILLA, P. G. (2006). *Dealing with Texture*.
- [Pichler et al., 1996] PICHLER, O., TEUNER, A. et HOSTICKA, B. J. (1996). A comparison of texture feature-extraction using adaptive gabor filtering, pyramidal and tree-structured wavelet transforms. *Pattern Recognition*, 29(5):733–742.
- [Pietikäinen et al., 2000] PIETIKÄINEN, M., OJALA, T. et XU, Z. (2000). Rotation-invariant texture classification using feature distributions. *Pattern Recognition*, 33:43–52.
- [Pietikäinen et al., 1983] PIETIKÄINEN, M., ROSENFELD, A. et DAVIS, L. (1983). Experiments with texture classification using averages of local pattern matches. *IEEE Transactions on Systems, Man, and Cybernetics*, 13(3):421–426.
- [Pujol et Radeva, 2004] PUJOL, O. et RADEVA, P. (2004). Texture segmentation by statistical deformable models. *International Journal of Image and Graphics*, 4:433–452.
- [Qin et al., 2008] QIN, L., ZHENG, Q., JIANG, S., HUANG, Q. et GAO, W. (2008). Un-supervised texture classification : Automatically discover and classify texture patterns. *Image and Vision Computing*, 26:647–656.
- [Radon, 1917] RADON, J. (1917). Über die bestimmung von funktionen durch ihre integralwerte langs gewisser mannigfaltigkeiten. *Berichte Sachsische Academie der Wissenschaften, Leipzig*, 69:262–267.
- [Randen et Husóy, 1999] RANDEN, T. et HUSÓY, J. H. (1999). Filtering for texture classification : A comparative study. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21:291–310.
- [Randen et al., 2000] RANDEN, T., MONSEN, E., ABRAHAMSEN, A., HANSEN, J. O., SCHLAF, J. et SONNELAND, L. (2000). Three-dimensional texture attributes for seismic data analysis. *In Society of Exploration Geophysicists*.
- [Rao, 1990] RAO, A. (1990). *A taxonomy for texture description and identification*. Springer Verlag.
- [Rao et Jain, 1992] RAO, A. et JAIN, R. (1992). Computerized flow field analysis : oriented texture fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14:693–709.
- [Rao et Schunck, 1991] RAO, A. et SCHUNCK, B. (1991). Computing oriented texture fields. *Graphical Models and Image Processing*, 53(2):157–185.
- [Rao et Lohse, 1993a] RAO, A. R. et LOHSE, G. L. (1993a). Identifying high level features of texture perception. *Graphical Models and Image Processing*, 55:218–233.
- [Rao et Lohse, 1993b] RAO, A. R. et LOHSE, G. L. (1993b). Towards a texture naming system : Identifying relevant dimensions of texture. *In VIS '93 : Proceedings of the IEEE international conference of Visualization*.
- [Reyes-Aldasoro, 2004] REYES-ALDASORO, C. C. (2004). *Multiresolution Volumetric Texture Segmentation*. Thèse de doctorat, University of Warwick.
- [Rosenfeld, 1970] ROSENFELD, A. (1970). Connectivity in digital pictures. *Journal of ACM*, 17:146–160.
- [Rosenfeld et Pfaltz, 1966] ROSENFELD, A. et PFALTZ, J. (1966). Sequential operations in digital picture processing. *Journal of ACM*, 13(4):471–494.

- [Rousson *et al.*, 2003] ROUSSON, M., BROX, T. et DERICHE, R. (2003). Active unsupervised texture segmentation on a diffusion based feature space. *In CVPR '03 : Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*.
- [Rousson *et al.*, 2004] ROUSSON, M., PARAGIOS, N. et DERICHE, R. (2004). Implicit active shape models for 3d segmentation in mr imaging. *In MICCAI '04 : Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*.
- [Sagiv *et al.*, 2006] SAGIV, C., SOCHEN, N. et ZEEVI, Y. (2006). Integrated active contours for texture segmentation. *IEEE transactions on image processing*, 15:1633–1646.
- [Sahiner *et al.*, 2004] SAHINER, B., CHAN, H.-P., ROUBIDOUX, M. A., HELVIE, M. A., HADJIISKI, L. M., RAMACHANDRAN, A., PARAMAGUL, C., LECARPENTIER, G. L., NEES, A. et BLANE, C. (2004). Computerized characterization of breast masses on three-dimensional ultrasound volumes. *Medical Physics*, 31:744–754.
- [Samet, 1984] SAMET, H. (1984). The quadtree and related hierarchical data structures. *ACM Computer Survey*, 16(2):187–260.
- [Sandberg *et al.*, 2002] SANDBERG, B., CHAN, T. et VESE, L. (2002). A level-set and gabor-based active contour algorithm for segmenting textured images. Rapport technique, Math. Departement UCLA.
- [Sarkar et Chaudhuri, 1992] SARKAR, N. et CHAUDHURI, B. (1992). An efficient approach to estimate fractal dimension of textural images. *Pattern Recognition*, 25:1035–1042.
- [Sarkar et Chaudhuri, 1994] SARKAR, N. et CHAUDHURI, B. (1994). An efficient differential box counting approach to compute fractal dimension of images. *IEEE Transactions on Systems, Man, and Cybernetics*, 24:115–120.
- [Saroul *et al.*, 2008] SAROUL, L., BERNARD, O., VRAY, D. et FRIBOULET, D. (2008). Prostate segmentation in echographic images : A variational approach using deformable super-ellipse and rayleigh distribution. *In ISBI '08 : Proceedings of the IEEE International Symposium on Biomedical Imaging*.
- [Savelonas *et al.*, 2008] SAVELONAS, M. A., IAKOVIDIS, D. K. et MAROULIS, D. (2008). Lbp-guided active contours. *Pattern Recognition Letters*, 29:1404–1415.
- [Schmid, 2001] SCHMID, C. (2001). Constructing models for content-based image retrieval. *In CVPR '01 : Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- [Selkäinaho *et al.*, 1988] SELKÄINAHO, K., PARKKINEN, J. et OJA, E. (1988). Comparison of  $\chi^2$  and  $\kappa$  statistics in finding signal and picture periodicity. *In ICPR '88 : Proceedings of the 9th International Conference on Pattern Recognition*, pages 1221–1224, Rome, Italy.
- [Sharma et Singh, 2001] SHARMA, M. et SINGH, S. (2001). Evaluation of texture methods for image analysis. *In ANZIIS '01 : Proceedings on the Seventh Australian and New Zealand Intelligent Information Systems Conference*.
- [Shen et Bai, 2008] SHEN, L. et BAI, L. (2008). 3d gabor wavelets for evaluating spm normalization algorithm. *Medical Image Analysis*, 12:375–383.
- [Shi et Funt, 2007] SHI, L. et FUNT, B. (2007). Quaternion color texture segmentation. *Computer Vision and Image Understanding*, 107:88–96.

- [Shoshany, 2008] SHOSHANY, M. (2008). An evolutionary patch pattern approach for texture discrimination. *Pattern Recognition*, 41:2327–2336.
- [Showalter *et al.*, 2006] SHOWALTER, C., CLYMER, B. D., RICHMOND, B. et POWELL, K. (2006). Three-dimensional texture analysis of cancellous bone cores evaluated at clinical ct resolutions. *Osteoporos International*, 17:259–266.
- [Sklansky, 1978] SKLANSKY, J. (1978). Image segmentation and feature extraction. *IEEE Transactions on Systems, Man, and Cybernetics*, 8:237–247.
- [Slabaugh *et al.*, 2006] SLABAUGH, G., UNAL, G., FANG, T. et WELS, M. (2006). Ultrasound-specific segmentation via decorrelation and statistical region-based active contours. In *CVPR '06 : Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*.
- [Soille et Rivest, 1996] SOILLE, P. et RIVEST, J.-F. (1996). On the validity of fractal dimension measurements in image analysis. *Journal of Visual Communication and Image Representation*, 7(3):217–229.
- [Sommer *et al.*, 1998] SOMMER, G., MICHAELIS, M. et HERPERS, R. (1998). The svd approach for steerable filter design. In *ISCAS'98 : Proceedings of the IEEE International Symposium on Circuits and Systems*.
- [Spann et Wilson, 1985] SPANN, M. et WILSON, R. (1985). A quad-tree approach to image segmentation which combines statistical and spatial information. *Pattern Recognition*, 18(3-4):257–269.
- [Stachowiak *et al.*, 2005] STACHOWIAK, G. P., PODSIADLO, P. et STACHOWIAK, G. W. (2005). A comparison of texture feature extraction methods for machine condition monitoring and failure analysis. *Tribology Letters*, 20(2):133–147.
- [Starovoitov *et al.*, 1998] STAROVOITOV, V. V., JEONG, S.-Y. et PARK, R.-H. (1998). Texture periodicity detection : Features, properties, and comparisons. *IEEE Transactions on Systems, Man, and Cybernetics*, 28(6):839–849.
- [Strand et Taxt, 1994] STRAND, J. et TAXT, T. (1994). Local frequency features for texture classification. *Pattern Recognition*, 27(10):1397–1406.
- [Suzuki *et al.*, 2004] SUZUKI, M. T., YOSHITOMO, Y., OSAWA, N. et SUGIMOTO, Y. (2004). Classification of solid textures using 3d mask patterns. In *ICSMC '04 : Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*.
- [Tamura *et al.*, 1978] TAMURA, H., MORI, S. et YAMAWAKI, T. (1978). Texture features corresponding to visual perception. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(6):460–473.
- [Tao *et al.*, 2003] TAO, Z., JAFFE, C. C. et TAGARE, H. D. (2003). Tunnelling descent : A new algorithm for active contour segmentation of ultrasound images. In *IPMI '03 : Proceedings of International Conference on Information Processing in Medical Imaging*.
- [Toyoda et Hasegawa, 2007] TOYODA, T. et HASEGAWA, O. (2007). Extension of higher order local autocorrelation features. *Pattern Recognition*, 40:1466–1473.
- [Trier et Taxt, 1995] TRIER, D. et TAXT, T. (1995). Evaluation of binarization methods for document images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17:312–315.

- [Tsai et Tseng, 1999] TSAI, D.-M. et TSENG, C.-F. (1999). Surface roughness classification for castings. *Pattern Recognition*, 32:389–405.
- [Tuceryan et Jain, 1990] TUCERYAN, M. et JAIN, A. K. (1990). Texture segmentation using voronoi polygons. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12:211–216.
- [Tuceryan et Jain, 1998] TUCERYAN, M. et JAIN, A. K. (1998). *Texture Analysis*, chapitre 2.1, pages 207–248. *The Handbook of Pattern Recognition and Computer Vision*.
- [Turner, 1986] TURNER, M. (1986). Texture discrimination by gabor functions. *Biological Cybernetics*, 55:71–82.
- [Tyler, 2004] TYLER, C. W. (2004). Theory of texture discrimination of based on higher-order perturbations in individual texture samples. *Vision Research*, 44:2179–2186.
- [Unser, 1984] UNSER, M. (1984). *Description statistique de la texture. Application à l'inspection automatique*. Thèse de doctorat, EPFL, Lausanne.
- [Unser, 1986] UNSER, M. (1986). Sum and difference histograms for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8:119–125.
- [Unser, 1995] UNSER, M. (1995). Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, 4:1549–1560.
- [Unser et Blu, 2003] UNSER, M. et BLU, T. (2003). Wavelet theory demystified. *IEEE Transactions on Image Processing*, 51:470–483.
- [Valckx et Thijssen, 1997] VALCKX, M. J. F. et THIJSSSEN, J. M. (1997). Characterization of echographic image texture by cooccurrence matrix parameters. *Ultrasound in Medicine and Biology*, 23(4):559–571.
- [Valkealahti et Oja, 1998] VALKEALAHTI, K. et OJA, E. (1998). Reduced multidimensional cooccurrence histograms in texture classification. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 20(1):90–94.
- [Valois et al., 1982] VALOIS, R. L. D., ALBRECHT, D. G. et THORELL, L. G. (1982). Spatial frequency selectivity of cells in macaque visual cortex. *Vision Research*, 22(5):545–559.
- [Vapnik, 1995] VAPNIK, V. (1995). *The Nature of Statistical Learning Theory*. Springer.
- [Varma et Zisserman, 2004] VARMA, M. et ZISSERMAN, A. (2004). Unifying statistical texture classification frameworks. *Image and Vision Computing*, 22:1175–1183.
- [Voorhees et Poggio, 1987] VOORHEES, H. et POGGIO, T. (1987). Detecting textons and texture boundaries in natural images. In *ICCV '87 : Proceedings of the First International Conference on Computer Vision*, pages 250–258, London.
- [Wang et He, 1990] WANG, L. et HE, D.-C. (1990). Texture classification using texture spectrum. *Pattern Recognition*, 23(8):905–910.
- [Wilson et Spann, 1988] WILSON, R. et SPANN, M. (1988). *Image Segmentation and Uncertainty*. New York : Wiley.
- [Wu, 1982] WU, F. (1982). The potts model. *Review of Modern Physics*, 54:235–268.
- [Xie et al., 2005] XIE, J., JIANG, Y. et TSUI, H. (2005). Segmentation of kidney from ultrasound images based texture and shape priors. *IEEE Transactions on Medical Imaging*, 24(1):45–57.

- [Younes, 1988] YOUNES, L. (1988). Estimation and annealing for gibbsian fields. *A. Inst Henri Pointcaré*, 24:269–294.
- [Yu et Aston, 2004] YU, Y. et ASTON, S. T. (2004). Edge detextion in ultrasound imagery using the instantaneous coefficient of variation. *IEEE Transactions on Image Processing*, 13:1640–1655.
- [Zhan et Shen, 2003] ZHAN, Y. et SHEN, D. (2003). Automated segmentation of 3d us prostate images using statistical texture-based matching method. *In MICCAI '03 : Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*.
- [Zhan et Shen, 2006] ZHAN, Y. et SHEN, D. (2006). Deformable segmentation of 3d ultrasound prostate image using statistical texture matching method. *IEEE Transactions on Medical Imaging*, 25(3):256–272.
- [Zhang et al., 2008] ZHANG, H., FRITTS, J. E. et GOLDMAN, S. A. (2008). Image segmentation evaluation : A survey of unsupervised methods. *Computer Vision and Image Understanding*, 110:260–280.
- [Zhang et Tan, 2002] ZHANG, J. et TAN, T. (2002). Brief review of invariant texture analysis methods. *Pattern Recognition*, 35:735–747.
- [Zhang et al., 1996] ZHANG, T., RAMAKRISHNAN, R. et LIVNY, M. (1996). Birch : An efficient data clustering method for very large databases. *In ACM SIGMOD '96 : Proceedings of the International Conference on Management of Data*.
- [Zhang, 1996] ZHANG, Y. (1996). A survey on evaluation methods for image segmentation. *Pattern Recognition*, 29(8):1335–1346.
- [Zhao et Pietikäinen, 2007] ZHAO, G. et PIETIKÄINEN, M. (2007). Dynamic texture recognition using local binary patterns with an application to facial expressions. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 29:915–928.
- [Zhongxiang et al., 2008] ZHONGXIANG, H., LEI, Z., JIAXU, T., XUEHONG, M. et XIAOJUN, S. (2008). Evaluation of three-dimensional surface roughness parameters based on digital image processing. *The International Journal of Advanced Manufacturing Technology*.
- [Zipf, 1935] ZIPF, G. (1935). *psycho-biology of languages*. Houghton-Mifflin.
- [Zucker, 1976] ZUCKER, S. (1976). Toward a model of texture. *Computal Graphics and Image Computing*, 5:190–202.
- [Zucker et Hummel, 1981] ZUCKER, S. W. et HUMMEL, R. A. (1981). A three-dimensional edge operator. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 3:324–331.



## BIBLIOGRAPHIE

---

## BIBLIOGRAPHIE

---

# Publications de l'auteur

## **Communications dans des conférences internationales avec actes :**

Ludovic Paulhac, Pascal Makris, Jean-Marc Grégoire, Jean-Yves Ramel : Human Understandable Features for Segmentation of Solid Texture, In ISVC'09 : 5th International Symposium on Visual Computing, Las Vegas, Nevada, USA, 12 pages, 2009.

Ludovic Paulhac, Pascal Makris and Jean-Yves Ramel : A Solid Texture Database for Segmentation and Classification Experiments, In VISAPP'09 : 4th International Conference on Computer Vision Theory and Applications, pp 135-141. Lisboa, Portugal. February 2009.

Ludovic Paulhac, Pascal Makris and Jean-Yves Ramel : Comparison between 2D and 3D Local Binary Pattern Methods for Characterisation of Three-Dimensional Textures. In ICIAR'08 : 5th International Conference on Image Analysis and Recognition, pp 670-679, Pòvoa de Varzim, Portugal, 25-27 juin 2008.

Ludovic Paulhac, Julien Olivier and Jean-Jacques Rouselle, Automatic Computation of Parameter in a Fast Level Set Method, In ICCCP'07 : International Conference on Communication, Computer and Power, pp 427-431, MUSCAT (SULTANATE OF OMAN), Feb 19-21 2007.

## **Communications dans des conférences francophones et nationales avec actes :**

Ludovic Paulhac, Pascal Makris, Jean-Marc Grégoire, Jean-Yves Ramel : Approche multirésolution pour la segmentation de textures dans les images ultrasonores 3D, In GRET-SI'09 : colloque du Groupe de Recherche et d'Etudes du Traitement du Signal, Dijon, France, September, 8-11 2009.

Ludovic Paulhac, Pascal Makris, Jean-Marc Grégoire, Jean-Yves Ramel : Descripteurs de Textures pour la Segmentation d'Images Echographiques 3D, In ORASIS'09 : Congrès Francophone de Vision par Ordinateur, Trégastel, France, Juin 2009.



## **Résumé :**

Le travail présenté dans cette thèse s'inscrit dans le domaine de l'analyse d'images texturées 3D aussi connu sous le nom de textures solides ou textures volumétriques. Partant de l'hypothèse qu'il est plus pertinent de décrire une texture avec des adjectifs qualificatifs plutôt qu'avec un modèle mathématique unique, nous avons choisi de définir un nouvel ensemble de descripteurs de textures permettant une caractérisation qualitative des textures contenues dans les images 3D. Ces nouveaux attributs permettent entre autres de décrire des propriétés texturales telles que la directionnalité, la rugosité, le contraste, la régularité ainsi que des informations de forme. Afin de les calculer, nous proposons un système multirésolution basé sur une décomposition en ondelette couplée à une analyse des composantes géométriques contenues dans les représentations obtenues. Ces caractéristiques sont exploitées par un logiciel, proposant une interface Homme-Machine interactive, afin de segmenter des images échographiques 3D.

## **Mots clés :**

Textures solides, caractéristiques de textures, multirésolution, segmentation d'images échographiques 3D, système interactif.

## **Abstract :**

This work deals with the domain of 3D textured images also known as solid textures or volumetric textures. Supposing that it is more relevant to describe a texture using qualifier adjectives than using a single mathematic model, we choose to define a new set of texture descriptors that allows us to have a qualitative characterisation of 3D images. These new attributes can quantify textural properties such as the directionality, the roughness, the contrast, the regularity but also information on shapes. To compute them, we propose a multiresolution system which associate a discrete wavelet transform and an analysis of geometric components content inside the obtained representations. A man-aided software using these texture features allows us to segment 3D ultrasound images.

## **Keywords :**

Solid textures, texture features, multiresolution, segmentation of 3D ultrasound images, interactive system.