



**THÈSE**  
PRÉSENTÉE  
À L'UNIVERSITÉ D'ORLÉANS  
POUR OBTENIR LE GRADE DE :

**DOCTEUR**  
**DE L'UNIVERSITÉ D'ORLÉANS**

**Discipline : Sciences et Technologies Industrielles**

PAR

*Arnaud CAPRI*

*Caractérisation des objets dans une image en vue d'une aide à  
l'interprétation et d'une compression adaptée au contenu :  
application aux images échographiques*

Soutenue le : \_\_/\_\_/2007

**MEMBRES DU JURY :**

- M. Jacques LÉVY-VÉHÉL	Directeur de Recherche	INRIA Rocquencourt	Rapporteur
- M. Henri MAITRE	Professeur	ENST Paris	Rapporteur
- M. Atilla BASKURT	Professeur	INSA Lyon	Examineur
- M. Loïc URBAIN	Responsable Bureau d'Etudes	ECA-Sinters	Examineur
- Mme Nicole VINCENT	Professeur	Université Paris 5	Codirectrice de thèse
- M. Pierre VIEYRES	Professeur	Université d'Orléans	Directeur de thèse



# Table des matières

<b>1</b>	<b>Introduction .....</b>	<b>1</b>
1.1	Le contexte .....	2
1.2	La position du problème.....	3
1.3	La contribution de nos travaux.....	4
1.3.1	<i>Contribution pratique</i> .....	4
1.3.2	<i>Contribution théorique</i> .....	5
1.4	L'organisation du manuscrit .....	5
<b>2</b>	<b>État de l'art : segmentation, évaluation puis caractérisation des composants d'une image. ....</b>	<b>8</b>
2.1	Introduction .....	10
2.2	Définition d'une image numérique .....	10
2.3	La segmentation d'image .....	12
2.3.1	<i>Définition</i> .....	12
2.3.2	<i>Différentes méthodes de segmentation</i> .....	12
2.4	La segmentation d'image en niveaux de gris.....	13
2.4.1	<i>Approche globale de l'image (pixellaire)</i> .....	13
2.4.2	<i>Approche région</i> .....	15
2.4.3	<i>Approche contour</i> .....	17
2.4.4	<i>Approche coopérative</i> .....	19
2.5	Méthodes supplémentaires pour la segmentation d'images texturées ...	20
2.5.1	<i>Les approches statistiques</i> .....	21
2.5.2	<i>Les approches structurelles</i> .....	22
2.5.3	<i>Les approches paramétriques</i> .....	22
2.6	Évaluation d'une segmentation .....	23
2.6.1	<i>Évaluation supervisée</i> .....	23
2.6.2	<i>Évaluation non supervisée</i> .....	32
2.6.3	<i>Discussion sur les méthodes d'évaluation.</i> .....	38
2.7	Représentation et modélisation des interfaces .....	38
2.7.1	<i>Les modèles géométriques</i> .....	38
2.7.2	<i>La modélisation polygonale</i> .....	40
2.7.3	<i>Les modèles Paramétriques</i> .....	40
2.7.4	<i>Les modèles multi-échelles</i> .....	41
2.8	Conclusion sur l'état de l'art .....	42
<b>3</b>	<b>Appréhension quantitative et qualitative des objets .....</b>	<b>44</b>

3.1	Introduction .....	46
3.2	Approches floue et fractale de la perception humaine .....	46
3.2.1	<i>Spécificité de la vision humaine</i> .....	47
3.2.2	<i>Introduction à la logique floue</i> .....	48
3.2.3	<i>Incertitude des « experts » face à un phénomène complexe</i> .....	49
3.2.4	<i>Introduction aux fractales</i> .....	50
3.2.5	<i>Présentation de la méthode envisagée</i> .....	55
3.3	L'approche floue .....	56
3.3.1	<i>Concepts, définitions</i> .....	56
3.3.2	<i>Approche théorique</i> .....	60
3.3.3	<i>Influence des paramètres <math>k</math> et <math>R</math></i> .....	64
3.4	Approche fractale pour le calcul de la complexité .....	73
3.4.1	<i>Approche théorique du calcul de complexité</i> .....	73
3.4.2	<i>Interface entre deux milieux texturés</i> .....	79
3.4.3	<i>Approche « pratique » : application aux images ultrasonores</i> .....	83
3.5	Conclusion .....	85
<b>4</b>	<b>Mise en œuvre théorique et pratique .....</b>	<b>87</b>
4.1	Introduction .....	89
4.2	Lien entre les approches floue et fractale .....	89
4.2.1	<i>Calcul du taux de flou de l'image observée</i> .....	89
4.2.2	<i>Lien entre le taux de flou et la complexité des interfaces</i> .....	91
4.2.3	<i>Complexité d'une interface réelle à partir d'une image bruitée</i> .....	93
4.2.4	<i>Conclusion</i> .....	97
4.3	Segmentation multi milieux .....	97
4.3.1	<i>Détermination du nombre de milieux constituant l'image</i> .....	97
4.3.2	<i>Segmentation par couples de milieux</i> .....	102
4.3.3	<i>Évaluation de la segmentation</i> .....	105
4.3.4	<i>Prétraitement d'une compression adaptée au contenu</i> .....	110
4.4	Éléments de Compression .....	110
4.4.1	<i>État actuel de la compression de données</i> .....	111
4.4.2	<i>Compression par IFS</i> .....	112
4.5	Conclusion .....	132
<b>5</b>	<b>Conclusion .....</b>	<b>134</b>
<b>6</b>	<b>Table des figures .....</b>	<b>138</b>
<b>7</b>	<b>Annexe .....</b>	<b>143</b>
	<i>Exemples de courbes fractales évaluées par la méthode proposée</i> .....	143

<b>8</b>	<b>Publications de l'auteur .....</b>	<b>149</b>
<b>9</b>	<b>Références .....</b>	<b>151</b>







# Chapitre 1

## 1 Introduction

---

Ce travail de thèse a été réalisé dans le cadre d'une convention CIFRE établie entre l'entreprise ECA-SINTERS de Toulouse et le Laboratoire de Vision et Robotique (LVR) de l'Université d'Orléans. Parmi les laboratoires collaborant à ces travaux figurent l'UMPS (Unité de Médecine et Physiologie Spatiale) de Tours et le CRIP5 (Centre de Recherche en Informatique Paris 5).

---

## **1.1 Le contexte**

La télémédecine est aujourd'hui un domaine pluridisciplinaire en plein essor. Son développement devrait permettre d'apporter une expertise médicale :

- dans les milieux isolés ou trop éloignés des centres référents.
- sur les sites d'intervention tels que les accidents de la route, où le temps est généralement compté et la vitesse de réactivité un élément déterminant pour assurer la survie des accidentés.

La télémédecine permet une prise en charge rapide des patients et une diminution des coûts liés aux transports entre les diverses structures hospitalières (cliniques, hôpitaux périphériques...) et l'hôpital référent. Pour l'expert, l'utilisation d'une telle technologie peut, entre autres, alléger les contraintes dans les hôpitaux périphériques et conforter une proposition de diagnostic en offrant la possibilité de faire appel à un deuxième avis médical.

Dans un grand nombre d'opérations de télémédecine, l'imagerie tient un rôle des plus importants. Parmi toutes les techniques existantes en radiologie, l'imagerie ultrasonore reste une très bonne candidate pour la médecine d'urgence. Non invasive, cette technique permet l'exploration de presque la totalité des organes du corps humain et renseigne l'expert sur l'état physiopathologique du patient. Cependant, cet acte ne peut être réalisé que par une personne compétente. La formation d'un échographiste, qui s'effectue sur 2 ans, est complétée par un apprentissage rigoureux et journalier qui permet au spécialiste d'acquérir la maîtrise du positionnement de la sonde échographique et d'y associer l'analyse médicale de l'image ultrasonore. S'ajoute à la nécessité d'une longue formation des échographistes, un manque d'experts en ultrasonographie qui sont très souvent regroupés dans les grands centres hospitaliers. Il est donc de plus en plus difficile à un patient de bénéficier d'un accès à des soins spécialisés, comme l'échographie, sur un lieu proche de son domicile. La télé-échographie robotisée apporte donc une solution d'accès aux soins de qualité sur des sites médicalement isolés et favorise l'échange d'expertise entre spécialistes du domaine pour le bénéfice du patient.

C'est dans ce contexte de la télémédecine robotisée et celui de la convention CIFRE que nous avons participé au développement, durant ces trois années, de plateformes de télé-opérations médicales :

- le robot de télé-chirurgie Endoxirob. Projet regroupant 9 partenaires dont l'entreprise ECA-SINTERS, le LAAS et le CEA.
- le robot de télé-échographie 3D pour l'IRISA de Rennes, développé par l'entreprise ECA-SINTERS.
- le robot léger de télé-échographie mobile OTELO2, projet européen composé de 9 partenaires dont le LVR de l'Université d'Orléans (porteur du projet), ECA-SINTERS, et l'UMPS du CHU de Tours.

## *1.2 La position du problème*

Ce dernier concept de télé-échographie mobile robotisée a été proposé par l'UMPS du CHU de Tours et développé par le LVR dès 1996. Il a été validé sur un premier robot prototype (projet SHISHA) [Gourdon, 2000], suivi de deux projets (TER-2000 et TERESA-2001) pendant lesquels deux autres plateformes robotisées ont été construites. Les enjeux prometteurs d'une telle application médicale à distance ont alors donné naissance à un projet européen OTELO (mObile Tele-Echography using an ultra-Light rObot, IST.2001-32516), regroupant 9 partenaires européens. Ce travail de thèse s'inscrit dans le prolongement de ces projets dans lesquels l'imagerie ultrasonore tient une place privilégiée.

La télé-échographie robotisée a pour but de déporter le geste médical sur un site distant (le poste « patient ») où il sera reproduit à l'aide d'un bras mécanique télé-opéré (un robot à 6 degrés de liberté, par exemple). En plus du bras manipulateur maintenu sur le corps du patient par un assistant paramédical, la télé-échographie nécessite, du côté du patient, l'utilisation d'un appareil échographique disponible (pouvant être transportable). Le flux vidéo envoyé au poste « expert », par des liaisons satellite ou terrestre, est souvent dégradé par les processus d'acquisition et de transfert des trames acquises. Au poste « expert », le spécialiste s'appuie sur l'image ultrasonore reçue pour effectuer son examen et contrôler, à l'aide d'une manette de contrôle appelée sonde pseudo-haptique, les positions et orientations du robot porte-sonde ; pour l'expert, l'acte de télé-échographie se déroule tout comme s'il se trouvait dans la salle d'examen à côté du patient.

### **1.2 La position du problème**

Dans le cadre de cet acte médical à distance, l'expert reçoit une image dégradée qui accroît la difficulté du diagnostic. La nécessité d'un traitement des images ultrasonores, afin d'apporter à l'expert un maximum d'informations utiles pour l'analyse, se fait alors sentir. De par la nature même de la construction des images ultrasonores, du moyen d'acquisition et du support de transmission, les images, souvent bruitées, sont difficilement analysables par des méthodes classiques de segmentation. Notre démarche consiste à extraire de ces images bruitées une caractérisation des divers objets la constituant afin d'apporter une aide à l'expert dans l'élaboration de son diagnostic. Nous nous plaçons dans un cas générique, permettant le traitement d'images diverses et variées (coupes d'organes différents) dont on ne possède aucune connaissance.

Une autre problématique soulevée par les applications robotiques pour la télémédecine réside dans le transfert de données. L'efficacité du contrôle du robot à distance dépend de la quantité d'informations disponible sur le réseau choisi et de l'influence du temps de retard intrinsèque aux communications. Ces informations sont véhiculées sur des lignes, parfois à bas débit (Internet, ligne numéris), qui dépendent de l'état des infrastructures présentes sur le site

isolé. Il est donc nécessaire de s'attacher à la compression d'informations et de chercher à minimiser la taille des fichiers de données transitant sur ces réseaux, sans dégrader les informations nécessaires à l'analyse et au contrôle de la chaîne de télé-échographie.

### **1.3 La contribution de nos travaux**

L'objectif premier de notre approche est d'extraire les caractéristiques des images afin d'apporter un niveau d'aide décisionnel et de confort supplémentaire à l'expert médical pour la proposition de son diagnostic. Dans le cadre de cette application de télé-échographie, le contrôle du robot est réalisé en boucle ouverte. L'image, reçue par l'expert via un lien de communication, est la seule information qui ferme cette boucle de contrôle et qui lui permet d'orienter l'effecteur du robot pour une meilleure visualisation d'un organe donné. L'identification des propriétés de l'image est donc une étape majeure qui conditionne les caractéristiques (débit, compression, qualité...) de l'image transmise et, par conséquent, la précision du positionnement de l'effecteur du robot et le diagnostic médical final. L'étude de ces propriétés permet donc, dans un deuxième temps, d'envisager une compression adaptée au support et à la dynamique du mouvement.

De part la convention CIFRE, la contribution de nos travaux se place à deux niveaux : une partie industrielle, essentiellement basée sur la conception et la mise au point de plateformes télé opérées ; et une partie plus théorique, basée sur la caractérisation des éléments constituant une image ultrasonore.

#### **1.3.1 Contribution pratique**

Notre implication dans de nombreux projets de Recherche et Développement au sein de l'entreprise ECA-SINTERS, en liaison avec la télé-échographie, la robotique et la reconstruction 2D/3D a débouché sur la finalisation de prototypes robotisés tels que :

- Le Robot Echo3D (Hippocrate) ; c'est un robot d'échographie 3D à 6 degrés de liberté. Ce robot d'architecture série est dédié à la télé-échographie. La particularité du système consiste en une station temps réelle QNX du côté du bras manipulateur permettant, entre autres, la synchronisation temporelle entre la position de la sonde et l'acquisition d'images.
- Le Robot de télé échographie OTELO2 ; ce robot d'architecture série à 6 degrés de liberté, mobile et portable permet à l'expert médical d'effectuer une échographie sur un patient distant de plusieurs centaines de kilomètres.
- Le Robots Endo*xi*rob ; est un robot dédié à la chirurgie invasive par laparoscopie. Il est composé de 3 bras articulés permettant d'actionner des outils chirurgicaux au travers d'un laparoscope. Un des bras permet de maintenir la caméra alors que les deux autres, manipulés à distance par le chirurgien via l'utilisation de bras phantom de la société

## 1.4 L'organisation du manuscrit

Haption, opère le sujet. Dans la continuité de ce projet, une application visant la mise au point puis l'asservissement de micro outils chirurgicaux à utiliser au travers du laparoscope ont été développés.

L'imagerie présente ces plateformes robotisées est au cœur de la deuxième contribution de nos travaux. Les aspects plus théoriques développées par la suite sont très souvent liés aux capteurs d'images présents sur les chaînes télé-opérées, et peuvent être implémentés sur les prototypes industriels développés précédemment afin de faciliter le contrôle à distance des robots médicaux..

### 1.3.2 Contribution théorique

➤ Segmentation et caractérisation des interfaces d'une image échographique.

Cette étape, que nous avons envisagée, consiste à développer une méthode de segmentation adaptée au contenu des images initialement « floues » telles que les images échographiques. Cette méthode de segmentation permet, entre autres, de caractériser les « objets » (régions) de l'image afin d'apporter une aide supplémentaire au praticien lors de sa prise de décision. Par analogie aux diverses régions composant l'image et pour lesquelles la texture est souvent aussi importante que la forme de la région elle-même, la caractérisation des interfaces entre ces diverses régions (par exemple réalisée par une mesure de leur complexité) est aussi significative que leur localisation exacte. Notre objectif est donc de caractériser les interfaces difficilement observables de par la nature même de l'image source.

➤ Outil de prétraitement pour une compression adaptée.

Les concepts de télé-opération et de transmission d'images impliquent la prise en compte des délais de transmission et un choix de méthode de compression de données. La démarche est de s'orienter vers le développement d'outils favorisant une compression adaptée d'une pat au contenu de l'image : des méthodes de compression par régions d'intérêt basées sur l'apprentissage des caractéristiques régions (les zones d'interfaces étant vues comme des régions) et la reconstruction de textures à partir de ces données (image de synthèse) ; et d'autre part à la dynamique du système : compression adaptée aux déplacements effectués par le médecin avec la sonde (mouvements rapides et amples pendant la phase de navigation, de recherche contre des mouvements lents et précis pendant la phase d'analyse).

## 1.4 L'organisation du manuscrit

Le document s'articule de la façon suivante. Le chapitre 2 présente un aperçu des méthodes de segmentation d'image ; il rassemble des travaux sur l'évaluation des résultats de segmentation et enfin sur la modélisation des interfaces. Cela nous permet alors de positionner nos travaux dans le chapitre suivant par rapport à l'existant. Dans ce chapitre 3, nous présentons les

## Introduction

théories floue et fractale à la base de notre approche avant de développer la partie théorique aboutissant à la caractérisation d'une interface positionnée entre deux milieux dans une image ultrasonore. Le chapitre 4 a pour but de montrer l'intérêt de notre approche. Il comprend deux parties : une partie théorique correspondant à la démonstration du lien existant entre les approches floue et fractale ; une partie pratique regroupant deux exemples d'utilisation de notre approche : la segmentation d'image, avec sa phase d'évaluation, et la compression adaptée au contenu. Nous concluons enfin par un bilan général sur l'apport de nos travaux et nous présentons les perspectives émergeant de ce travail.



## Chapitre 2

# **2 État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.**

---

Ce chapitre présente un panel des différentes méthodes de segmentation d'image présentes dans la littérature ainsi que les méthodes permettant leur évaluation. Enfin, des méthodes de modélisation et/ou caractérisation des divers objets constituant une image numérique sont présentées. Des conclusions sur chacune des méthodes sont établies et nous permettent de dégager une démarche à suivre pour répondre à la problématique posée par la caractérisation des objets présents dans une image multi-milieux.

---

#### *1.4 L'organisation du manuscrit*

### 2.1 Introduction

Le but de l'analyse d'image réside dans la description (forme, couleur, texture) et/ou la quantification (nombre, densité) des divers objets qui composent l'image étudiée. L'analyse trouve sa place dans de nombreux domaines tels que la robotique, les sciences de la vie ou encore la médecine. En effet, bien souvent, les médecins établissent un diagnostic en fonction de leurs acquis, leurs expériences. Les notions de segmentation et de description objective des composants formant l'image offrirait à l'expert un complément d'informations (quantifiées) lui permettant d'étayer son diagnostic.

Dans ce chapitre, suite à une brève définition de la notion d'image numérique, nous présenterons un aperçu sur les méthodes de segmentation d'image ; segmentation d'image qu'il est, encore aujourd'hui, difficile d'évaluer. Nous présenterons donc, ensuite, une liste non exhaustive de méthodes permettant d'évaluer les résultats obtenus. Puis, nous ferons le point sur les méthodes actuelles de modélisation de divers contours. Enfin, en conclusion, nous ferons le point sur ces différents aspects et nous replacerons l'approche présentée dans ce manuscrit dans divers contextes.

### 2.2 Définition d'une image numérique

Avant de s'intéresser à l'image numérisée, il semble bon de revenir sur la notion d'image. Au sens étymologique, le mot « image », découlant du latin *imago*, désigne la représentation visuelle d'un objet par différents moyens ou supports (dessin, photographie, peinture, sculpture ...).

L'image d'un objet peut alors être interprétée comme un ensemble de points sur une surface plane. Bien évidemment, la représentation s'effectuant dans un plan, la notion de profondeur n'est pas conservée mais peut être obtenue par un procédé de stéréoscopie en utilisant deux vues de l'objet prises à partir de deux positions différentes [Gonzales et Wintz, 1987] [Albouy et al., 2006].

Un moyen simple pour créer une image consiste en l'utilisation de capteurs comme par exemple les caméras et appareils photographiques. On distingue deux types de capteurs pour les acquisitions d'images : les capteurs passifs qui captent directement le rayonnement lumineux émis par une source de la scène (par exemple la rétine humaine réagissant aux rayons lumineux émis par le soleil ou tout autre objet réfléchissant sa lumière) ; les capteurs actifs qui émettent un signal (par exemple une onde électromagnétique ou ultrasonore irradiant la scène) puis qui captent l'onde réfléchi par l'objet (nous pouvons citer le laser Hene avec une longueur d'onde de 0,633  $\mu\text{m}$  ou encore les sondes ultrasonores pouvant atteindre 5,3 mm de longueur d'onde).

## 2.2 Définition d'une image numérique

Les données brutes acquises par ces systèmes de capture peuvent être utilisées comme telles ou traitées de façon à être exploitées par la suite. Un des traitements du signal brut (analogique) correspond à sa numérisation.

### Définition :

Une image numérisée correspond à une image acquise, puis traitée de façon à être stockée sous forme binaire (succession de bits à 0 ou 1).

Le stockage de l'image numérique ainsi obtenue peut s'effectuer sous différents formats (jpeg, bmp, tiff, png, gif...). Ils correspondent à des mécanismes de compression différents, mais une image de même taille que l'image originale peut être reconstituée. Cette image restituée est composée d'éléments communément appelés « pixels » (terme issu de la contraction des mots anglais « picture » et « element »).

La phase de numérisation effectuée, vient ensuite une phase plus complexe d'interprétation de l'image (traitement de l'image, identification des composants, compréhension du phénomène). Elle a pour but d'extraire des informations (orientation, couleur, forme) sur les objets et de décrire leurs interactions, leurs relations. Les systèmes de perception artificiels peuvent percevoir dans des domaines de longueurs d'onde bien plus étendus que ne peut le faire l'être humain (infrarouge, ultraviolet, ultrasons) mais ne sont cependant pas capables d'interpréter une image automatiquement. Dans [Besançon, 1988], T.Kanade et H.Simon signalent « qu'un ordinateur sait mieux jouer aux échecs que distinguer une chaise d'un fauteuil ». L'informatique ne rivalise pas encore avec le cerveau humain, plus efficace, dans l'analyse et la compréhension d'un phénomène. C'est pourquoi de nombreuses méthodes visant à comprendre puis modéliser certaines fonctions du corps humain (la vision, le cerveau, les coopérations dans le système immunitaire, la génétique...) émergent aujourd'hui.

A l'état le plus avancé de cette phase d'interprétation, les objets sont distincts et caractérisés. Pour arriver à un tel résultat, l'étape de segmentation de l'image initiale en objets est indispensable. Nous allons donc, dans ce manuscrit, commencer par faire un état de l'art sur les méthodes de segmentation disponibles rencontrées dans la littérature. Cette étape nous permettra de faire un choix sur le type de méthode envisagée pour décomposer une image ultrasonore en objets distincts. Le choix sera d'autant plus crédible qu'une phase d'évaluation des divers résultats de méthodes de segmentation sera utilisée. Le choix de cette méthode d'évaluation sera rendu possible par l'état de l'art proposé dans une seconde partie. Pour finir, la méthode de segmentation retenue devra nous permettre de partitionner l'image à traiter en objets distincts ; ces objets devront alors être analysés ; on se propose alors d'étudier les diverses possibilités existantes quant à la caractérisation et la modélisation d'objets.

## **2.3 La segmentation d'image**

### **2.3.1 Définition**

En traitement d'image, la segmentation est un procédé qui a pour but de rassembler les pixels de l'image étudiée en régions selon des critères prédéfinis. Un traitement visant à extraire uniquement deux régions de l'image initiale peut être vu comme une binarisation. Si l'homme est actuellement capable de différencier, dans une image quelconque, les objets la constituant, c'est parce qu'il est capable de comprendre les mécanismes, les relations liant les divers objets de la scène. Les algorithmes de haut niveau capables d'arriver à un tel résultat ne sont pas encore d'actualité.

Nous pouvons adopter la définition suivante pour la segmentation :

"La segmentation est un traitement de bas niveau qui consiste à créer une partition de l'image  $A$  en sous-ensembles  $R_i$ , appelés *régions* tels qu'aucune région ne soit vide, l'intersection entre deux régions soit vide et l'ensemble des régions recouvre toute l'image. Une *région* est un ensemble de pixels connexes ayant des propriétés communes qui les différencient des pixels des régions voisines." [Cocquerez et Philipp, 1995].

La définition des régions est donc basée sur une similarité matérialisée dans la propriété « P » définie en chaque pixel de l'image. Cette propriété peut être l'intensité du niveau de gris du pixel ou tout vecteur d'attributs (vecteurs de moments par exemple).

### **2.3.2 Différentes méthodes de segmentation**

Dans l'objectif d'analyser une image, la segmentation est alors une étape primordiale. On regroupe de façon usuelle les méthodes de segmentation en 4 groupes [Cocquerez et Philipp, 1995] [Nikolaidis et Pitas, 2001] [Trémeau et al., 2004] [Maitre, 2003] basés respectivement sur :

- une approche globale de l'image,
- la recherche de « frontières »,
- la recherche de « régions »,
- la coopération entre les trois premières.

Ces méthodes permettent de segmenter l'image en régions homogènes (par rapport à la texture, la couleur, la distribution des niveaux de gris...). Le résultat correspond à un partitionnement de l'image ; chaque pixel est en effet étiqueté de façon à indiquer son appartenance à telle ou telle région. On peut alors l'interpréter comme une classification des pixels en  $n$  classes (régions).

De plus, on peut ajouter à ces méthodes, permettant de gérer la texture en prenant pour vecteur d'attributs des variables prenant en compte un modèle de la texture, des méthodes spécifiques à la segmentation d'images texturées.

### **2.4 La segmentation d'image en niveaux de gris**

De manière non exhaustive, nous proposons ici un panorama des diverses méthodes de segmentation utilisées pour partitionner les images en niveaux de gris.

#### **2.4.1 Approche globale de l'image (pixellaire)**

Le principe consiste à regrouper les pixels selon leurs attributs (intensité, contraste, vecteur moment) sans tenir compte de leur localisation au sein de l'image. Cela permet de construire des classes de pixels ; les pixels adjacents, appartenant à une même classe, forment alors des régions. Parmi les approches pixellaires, on distingue les méthodes par seuillage, basées uniquement sur un seul attribut (souvent l'intensité du pixel), des méthodes permettant une classification multi attributs (par exemple l'intensité du pixel et un calcul de distances). L'objectif consiste à affecter à chaque pixel de l'image une étiquette  $e_i$  indiquant la classe (région)  $i$  la plus proche (mesure de distance entre le pixel et le centre de gravité de la classe).

##### ➤ Les méthodes à seuils

Le seuillage d'histogramme (thresholding) est l'une des méthodes de segmentation les plus simples à implémenter ; cette approche va séparer les éléments d'une image en se basant uniquement sur l'intensité de niveaux de gris des éléments la constituant. Elle consiste à repérer les modes de l'histogramme (zones de forte densité) et rechercher les frontières entre ces modes dans les zones de faible densité. Cette méthode est donc basée sur l'hypothèse forte qu'à chaque mode de l'histogramme correspond une région. Si un seuillage simple est utilisé, on obtient une séparation de l'histogramme en deux milieux uniquement. Pour les cas plus complexes d'histogrammes présentant plus de deux classes, un seuillage multiple devient nécessaire.

Ainsi, chaque pixel de l'image est classé selon son niveau de gris et les seuils prédéfinis. Cependant, il arrive souvent d'avoir à traiter des images représentant des objets d'intensités homogènes uniquement localement. On peut alors recourir à un seuillage non uniforme de l'image. Des seuillages adaptatifs seront alors appliqués sur différentes zones de l'image.

Ces méthodes ont fait l'objet de nombreuses recherches dans l'estimation d'un seuil optimal [Ridler et Calvard, 1978] [Otsu, 1979] [Kapur et al., 1985] [Glasbey, 1993] [Sankur et Sezgin, 2004]. Cependant, elles ne sont utilisables que dans le cas d'images peu bruitées, constituées d'objets d'intensités homogènes et significativement différentes d'un objet à l'autre.

## État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

Une autre approche consiste en la modélisation de l'histogramme des niveaux de gris par un mélange de distributions. La recherche des modes s'effectue ici par des méthodes de classification statistiques [Mardia et Hainsworth, 1988] [Pal et Pal, 1991]. L'histogramme d'intensités de l'image peut alors être perçu comme un mélange de Gaussiennes. Les seuils de classification sont alors choisis de façon à éviter les mauvaises affectations. Bien évidemment, le choix des distributions utilisées est un élément déterminant dans la qualité du résultat.

### ➤ La classification (clustering)

Cette méthode consiste à regrouper et à classer les pixels d'une image en classes en fonction de leurs propriétés. A chaque point de l'image est associé un vecteur d'attributs. La classification est alors effectuée sur ces vecteurs d'attributs de façon à aboutir à un nombre restreint de régions homogènes au sein de l'image. Il existe deux grandes tendances : la classification supervisée, basée sur l'apprentissage de propriétés discriminantes sur un échantillon de données déjà classées, et la classification non supervisée basée sur une mesure de distance entre les vecteurs d'attributs. Nous présentons ici trois méthodes de classification qui nous paraissent être les plus utilisées :

#### - Les k-plus-proches-voisins

Cette approche supervisée, nécessitant une phase d'apprentissage, va classer chaque pixel de l'image en fonction de la classe d'appartenance des pixels de son voisinage (des k voisins plus proches en terme de distance entre leurs attributs et/ou leurs localisations spatiales) [Jain et Dudes, 1988]. Contrairement à l'algorithme des k-moyennes, cette méthode est robuste même si les régions distinctes s'interpénètrent. Cette approche ne tenant toutefois pas compte des interactions spatiales entre pixels d'une même image, [Cocquerez et Philipp, 1995] ont proposé une méthode de relaxation permettant de corriger la présence de pixels isolés.

#### - Les k-moyennes

Méthode non supervisée, elle nécessite cependant de connaître, *a priori*, le nombre de classes de l'ensemble d'arrivée. A l'initialisation, on choisit de façon aléatoire « n » centres de gravité (« n » étant le nombre de classes souhaitées). On affecte alors à chaque pixel l'étiquette de la classe la plus proche (en prenant par exemple la distance euclidienne ou la distance entre les vecteurs d'attributs comme critère d'affectation) puis les centres de gravité sont recalculés. On réitère le processus jusqu'à stabilisation des centres de gravité (pas de variation entre deux itérations successives). Cette méthode, sensible à l'initialisation des centres de gravité (risque de solution locale pas forcément optimale) n'est de plus pas robuste pour l'analyse d'images présentant des régions de formes quelconques (la frontière entre deux régions

## 2.4 La segmentation d'image en niveaux de gris

adjacentes correspond à un segment, d'où la limitation de forme, dont chaque point est équidistant des deux centres de gravité des deux régions).

Quelques variantes de cet algorithme existent :

- Une généralisation sous le nom de nuée dynamique ;
- La méthode des « k-moyennes floues », considérant qu'un pixel peut appartenir à différentes classes avec des degrés d'appartenance différents compris dans l'intervalle  $[0, 1]$ , est une amélioration des k-moyennes ;

### - Réseaux de neurones

Méthode supervisée nécessitant une phase contraignante d'apprentissage, les réseaux de neurones sont capables d'établir des relations entre les données en entrée du réseau et le résultat en sortie. Un réseau particulier peut par exemple retourner la classe à laquelle appartient le pixel à partir de son niveau de gris et d'une connaissance du voisinage [Duda et al., 2001]. Ce système bien que fournissant de manière automatique un résultat reste très difficile à mettre en place. Le choix de l'architecture du réseau tout comme la taille de l'échantillon initial indispensable à l'apprentissage (risque de sous et sur échantillonnage) restent aujourd'hui des paramètres non déterminés analytiquement.

## 2.4.2 Approche région

L'objectif de ces méthodes consiste toujours à partitionner l'image traitée en régions homogènes ; chaque objet de l'image pouvant être ainsi constitué d'un ensemble de régions. Dans le but de produire des régions volumineuses et afin d'éviter une division parcellaire des régions, un critère de proximité géographique peut être ajouté au critère d'homogénéité. Au final, chaque pixel de l'image reçoit une étiquette lui indiquant son appartenance à telle ou telle région. On obtient ainsi une carte des régions de l'image.

On distingue deux familles d'algorithmes pour l'approche région : les méthodes de croissance de régions qui agrègent les pixels voisins (méthodes ascendantes [Zhu et Yuille, 1996]) selon le critère d'homogénéité (intensité, vecteur d'attributs) ; les méthodes qui fusionnent ou divisent les régions en fonction du critère choisi (méthodes dites descendantes).

### ➤ La croissance de région

La croissance s'effectue à partir de pixels initiaux appelés « germes ». Ces germes peuvent être sélectionnés de façon aléatoire ou automatique [Cocquerez et Philipp 1995]. Lors d'une itération du processus, les pixels adjacents à la région sont étudiés. S'ils vérifient les conditions d'homogénéité (critère défini au préalable), le pixel sera alors agrégé dans la région. Les pixels non intégrés aux régions peuvent générer eux-mêmes de nouvelles régions ou être quand même assimilés à la région la plus proche (cas du bruit

### État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

dans une image par exemple). Généralement, une mesure de similarité peut être évaluée par un calcul de distance entre les attributs du pixel candidat et ceux de la région. Lorsqu'une région intègre un nouvel élément, ses attributs sont alors remis à jour.

La croissance de région s'interrompt lorsque tous les pixels adjacents aux régions ont été affectés. L'approche demeure efficace lorsque les paramètres de critères d'homogénéité (intensité et spatial), de choix de germes, de choix du parcours des pixels candidats, de seuils, sont bien choisis. En effet, la méthode reste très sensible à la variation d'un de ces paramètres et le résultat final en est fortement dépendant. Cette méthode est donc bien adaptée aux séquences d'images présentant de faibles variations comme par exemple les images d'une acquisition vidéo. Le choix des paramètres est alors effectué sur la première image, puis conservé pour l'ensemble des images suivantes [Zhang et al., 2004] [Lezoray, 2000].

#### ➤ Les méthodes de décomposition et fusion (« Splitting and Merging »)

Le principe consiste en une alternance de phases de division et de fusion de régions jusqu'à optimiser un critère d'homogénéité choisi préalablement [Yang, 1988]. Pour l'étape de fusion, on recherche dans les couples de régions possibles (régions adjacentes quasi similaires), ceux candidats à un possible regroupement. Chaque couple retenu est noté en fonction de l'impact qu'aurait sa fusion sur le critère d'homogénéité global. Les couples les mieux notés sont alors fusionnés. L'étape de décomposition (division) agit de façon opposée ; les régions les moins homogènes sont alors divisées en régions plus petites. Le processus de division peut, dans le cas extrême, aboutir à un maillage de l'image sous forme de pixels indépendants. Le résultat final est obtenu lorsque la condition d'arrêt prédéfinie est atteinte (nombre de régions, contraste) ou lorsque les notes attribuées aux couples candidats à la fusion n'évoluent plus significativement. Dans [Maes, 1998], l'image est d'abord partitionnée en utilisant les lignes de partage des eaux avant la fusion des régions similaires ainsi obtenues.

Deux des méthodes de décomposition et fusion de régions les plus utilisées reposent sur le diagramme de Voronoï [Chassery et Melkemi, 1991] et l'utilisation d'un arbre quaternaire.

#### Diagramme de Voronoï

L'utilisation du diagramme de Voronoï permet un partitionnement de l'image en polygones. A l'initialisation, le diagramme est construit sur un ensemble de germes sélectionnés de façon aléatoire sur l'image via un processus de Poisson. L'application des phases de fusion et de décomposition permet la suppression de régions (et de germes) superflus ainsi qu'une décomposition des régions hétérogènes au sens du critère adopté initialement.

### Arbre quaternaire (« quadtree »)

Le principe consiste à diviser l'image initiale en régions rectangulaires répondant toutes au critère d'homogénéité avant d'appliquer la phase de fusion. Partant de l'image comme région initiale, on construit l'arbre en subdivisant en quatre la région si elle ne répond pas au critère d'homogénéité. On réitère alors l'opération sur les 4 régions filles si besoin. Chaque nœud de l'arbre contient alors exactement quatre nœuds fils. Une fois l'arbre quaternaire établi, certaines feuilles de l'arbre ont des caractéristiques similaires ; elles sont alors regroupées ensemble durant la phase de fusion. Cette méthode, bien que plus rapide dans le traitement des données, fournit un résultat présentant une approximation grossière des frontières (en marches d'escalier).

En conclusion, l'approche région décompose bien l'image initiale en régions aux contours fermés répondant au critère d'homogénéité souhaité. Cependant, ces méthodes restent sensibles à beaucoup de paramètres comme le sens de parcours des diverses régions ou encore l'initialisation des germes. Cette approche propose de plus une mauvaise gestion, erreurs d'affectation, des pixels placés à la « frontière » d'au moins deux régions.

### **2.4.3 Approche contour**

Duales des approches région, les approches contour ne cherchent plus à trouver les régions elles-mêmes mais leurs frontières. Essentiellement basées sur des mesures de gradients au sein de l'image, elles consistent en une étude locale de recherche de discontinuités [Cocquerez et Philipp, 1995]. Elles exploitent le fait qu'il existe une transition décelable entre deux régions adjacentes. Les contours extraits via les calculs des dérivées première et seconde (nous permettant de détecter les zones de forte variation) ne sont généralement pas fermés et/ou continus. Il est donc souvent nécessaire d'associer une méthode de suivi et/ou de fermeture des contours [Pratt, 2001] selon le résultat escompté.

On discerne trois grandes familles d'approches :

➤ Les méthodes de calculs de gradients discrets

L'utilisation des filtres tels que ceux de Sobel, Prewitt ou encore Roberts permet de calculer les gradients locaux en tout point de l'image. Ils permettent de discrétiser le calcul des dérivées. Ces méthodes, bien que rapides à implémenter, ne sont malheureusement pas robustes au bruit.

➤ Les détecteurs de contour

On peut citer les détecteurs de Canny [Canny, 1986], Deriche [Deriche, 1987], Marr-Hildreth [Marr et Hildreth, 1980] ou celui plus récent de Bao

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

[Bao et al., 2005]. Une fois la norme et la direction du gradient calculées en chaque pixel de l'image, ces méthodes extraient des contours d'un seul pixel d'épaisseur en sélectionnant les maxima locaux des normes des gradients. De plus, l'utilisation d'une méthode de simple ou multi seuillage, permet de supprimer les pixels isolés et au contraire de prolonger certaines portions de contours. Ces méthodes de seuillage ne sont pas parfaites et le résultat final correspond souvent à un ensemble de contours non fermés, ne délimitant pas des régions. Pour les opérateurs de Canny et de Deriche, une variable supplémentaire permet d'ajuster la sensibilité de la détection au détriment de la précision spatiale du contour et *vice versa*. On peut de plus noter que la détection de contours dans les zones à forts gradients ne correspond pas forcément à un objet. Dans ce cas, un post-traitement peut s'avérer efficace.

Ces méthodes, de mise en œuvre simple, donnent de bons résultats pour l'analyse d'image représentant des objets non texturés, fortement contrastés, aux contours marqués.

➤ Les modèles déformables

Les modèles déformables, introduits par Kass et Terzopolous [Kass et al., 1987] [Terzopolous et al., 1998] sont aussi connus sous les noms de « snakes » ou « contours actifs ». Un contour actif agit comme un élastique. Initialisé proche du contour à trouver, il modifie sa forme de façon à venir épouser celle de la frontière recherchée. Différents types de forces lui sont appliqués de façon à induire ce comportement. Mentionnons principalement : les forces dites « internes », qui contrôlent la régularité de la courbe ou surface recherchée [Nikolaidis et Pitas, 2001], et les forces « externes » liées aux attributs de l'image.

Ces méthodes offrent une alternative aux méthodes citées précédemment. Les modèles déformables sont en effet peu sensibles au bruit et gèrent de façon efficace les contours irréguliers. De plus, les modèles déformables appartenant au domaine continu, les contours obtenus ont une précision supérieure à la résolution de l'image étudiée. Ces méthodes sont beaucoup employées dans l'imagerie médicale [Delingette et Montagnat, 2001] où la comparaison entre un modèle témoin et celui issu d'un modèle déformable sur une image (2D comme 3D) renseigne l'expert sur une possible anomalie. D'autres approches consistent en un modèle déformable géométrique [Malladi et al., 1995] ou un modèle fondé sur les ensembles de niveaux [Osher et Sethian, 1988] ; le contour actif est alors défini comme une courbe de niveau (ensemble de points de valeurs identiques) [Dufour et al., 2005].

L'inconvénient majeur de ces méthodes réside dans l'initialisation du contour actif et le choix des poids influençant l'impact des forces en présence (internes et externes). Ces méthodes nécessitent donc d'avoir une connaissance *a priori*, de l'environnement étudié et de l'objet recherché. C'est

## 2.4 La segmentation d'image en niveaux de gris

une méthode de segmentation un peu particulière correspondant plus à l'extraction d'objets.

En conclusion, ces méthodes de détection de contours permettent d'obtenir au final une carte des divers contours présents dans l'image. Bien souvent, ces contours ne sont ni fermés, ni continus. On a alors recours à des opérations de fermetures morphologiques ou aux méthodes de suivi de contours ; appliquées sur la carte binarisée ou non des contours, ces approches permettent d'améliorer le résultat. Une autre possibilité peut être d'appliquer conjointement deux méthodes d'extraction de contours. La méthode des modèles déformables peut par exemple être utilisée pour améliorer un résultat grossier obtenu au préalable. Ces méthodes présentent un grand intérêt dans la problématique du suivi de contours. Dans le cas d'une séquence vidéo, ou d'un ensemble d'images très proches visuellement, les contours actifs peuvent être une solution rapide au traitement des images successives ; une fois le modèle déterminé sur la première image, l'appliquer sur l'image suivante peut être beaucoup plus efficace que de tout recalculer. Il ne faut cependant pas avoir de différences trop importantes entre deux images successives.

### 2.4.4 Approche coopérative

Dans cette catégorie, on compte les approches hybrides ou mixtes, elles consistent à combiner les résultats de diverses méthodes afin d'en ajouter leurs avantages. Globalement, une approche contour permet la localisation des frontières, des contours, non continus donc difficilement utilisables. En y joignant une approche région dont les caractéristiques sont l'obtention de zones fermées et homogènes, on peut ainsi pallier les faiblesses de chacune des techniques : la faible précision du contour (approche région) et l'obtention de régions non fermées (approche contour).

On distingue différentes catégories de méthodes mixtes :

- Par fusion de résultats obtenus avec diverses méthodes

Citons l'exemple d'une coopération entre une méthode basée croissance de régions et une méthode par modèle déformable. Dans [Zhu et Yuille, 1996], la compétition entre régions fait se développer une région de couleur homogène tout en limitant les contours irréguliers.

- Par utilisations successives des approches contour et région

La méthode région va alors utiliser la carte de contours obtenue via l'application d'une approche contour. Elle permet d'accroître la précision des frontières entre régions. Un exemple de cette approche peut être l'utilisation d'une approche par croissance de régions en forçant les frontières à épouser la

## État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

carte des contours obtenue par une des approches contour explicitées précédemment.

### ➤ Par utilisation simultanée de méthodes basées contour et région

Le résultat est alors construit de façon dynamique au cours du processus de segmentation. La méthode développée dans [Pavlidis et Liow, 1990] propose une amélioration de la méthode de division-fusion liée à l'arbre quaternaire en y ajoutant une méthode similaire aux modèles déformables. Les deux premières phases de l'algorithme sont en effet celles de la division-fusion : création de l'arbre quaternaire sur un critère d'homogénéité puis fusion des régions voisines selon ce même critère. La troisième phase correspond à l'utilisation d'un modèle déformable tenant compte de la norme du gradient local et de la courbure du contour. Cette méthode propose l'avantage de lisser les contours obtenus par la simple application de la méthode de division-fusion du « quadtree » mais reste cependant fortement liée à l'arbre quaternaire et nécessite le réglage de nombreux paramètres.

## **2.5 Méthodes supplémentaires pour la segmentation d'images texturées**

La plupart des méthodes de segmentation étudiées précédemment sont applicables à la segmentation d'images texturées. A chaque pixel est alors associé un vecteur d'attributs traduisant les propriétés de la texture de façon locale (voisinage). La phase de segmentation, correspondant à la détermination des diverses frontières, régions, s'effectue alors par comparaison de ces différents vecteurs d'attributs. Cette étape s'effectue via des mesures de distances entre les vecteurs d'attributs et non plus uniquement l'intensité du niveau de gris du pixel.

D'autres méthodes de segmentation plus spécifiques permettent l'analyse des images texturées. L'objectif de telles approches consiste à segmenter l'image en objets selon leurs textures. Cependant, comme le soulignent à maintes reprises les chercheurs dans la littérature :

- "Texture has been extremely refractory to precise definition" [Haralick et al., 1973] ;
  - "There is no universally accepted definition of texture" [Cross et Jain, 1983] ;
  - "Texture eludes precise definition" [Picard, 1991] ;
- la notion de texture n'est pas facilement formalisable.

Toutefois, deux observations sur les textures font l'unanimité dans la littérature :

- Il peut exister une variation significative entre les pixels voisins d'une même texture.
- Une texture montre une certaine homogénéité à une échelle d'observation donnée.

Ainsi, certaines approches cherchent à analyser la texture en essayant de reproduire le système de vision humaine [Bovik et al., 1990] ; une texture, montrant de fortes variations d'intensité à une échelle d'observation donnée, pourra alors être perçue comme plus homogène à une échelle d'observation supérieure.

Beaucoup de travaux [Tuceryan et Jain, 1993] se sont intéressés à la segmentation d'images texturées et à leur caractérisation. On peut regrouper les différentes approches en trois grandes catégories :

- Les approches statistiques,
- Les approches structurelles,
- Les approches paramétriques.

### 2.5.1 Les approches statistiques

Cherchant à estimer les paramètres de la texture à segmenter, le modèle de la texture est généralement assimilé à un vecteur d'attributs, un ensemble de nombres, décrivant au mieux la texture. Ces méthodes se basent souvent sur la corrélation que peut avoir un pixel de la texture avec ses voisins.

On distingue les méthodes basées sur :

➤ L'utilisation de la matrice de co-occurrences [Haralick et al., 1973]

Beaucoup d'applications visant à classer des images texturées utilisent des critères dérivés de la matrice de co-occurrences (énergie, entropie, contraste). Ces méthodes donnent de bons résultats mais nécessitent beaucoup de temps de calcul. [Argenty et al., 1990] proposent alors un algorithme permettant de calculer plus rapidement les matrices de co-occurrences.

➤ Le calcul du nombre de pixels partageant les mêmes attributs dans toutes les directions de l'espace

Cette méthode a été utilisée par [Galloway, 1975] pour classer des images de terrains.

➤ L'étude des variations d'énergie au sein de la texture [Laws, 1980]

Dans [Laws, 1980], l'auteur utilise 9 masques de convolution différents sur toute l'image. Chaque pixel se voit alors affecter un vecteur d'attributs composé de 9 mesures différentes d'énergie. C'est par comparaison de ces vecteurs que sont extraites les différentes régions (selon un critère d'homogénéité).

➤ La répétition des structures de base

Il existe beaucoup d'approches centrées sur l'étude, par exemple, de la granulométrie des matériaux [Dougherty et al., 1989].

## État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

### ➤ L'évolution en fonction de l'échelle d'observation

Le principe des ondelettes ou simplement le modèle de pyramides de décomposition (pyramide Gaussienne, Laplacienne...) peuvent être utilisés pour la classification de texture [Mallat, 1989] [Chang et Kuo, 1993]. Une approche multi échelles utilisant des filtres de Gabor, pour l'extraction des primitives de base, constitue un autre exemple de segmentation non supervisée de texture [Puzicha et al., 1996].

### ➤ La redondance spatiale des éléments

Déterminées à partir d'une fonction d'auto-corrélation ou de l'application d'une transformée (type Fourier ou Hadamard) [Sonka et al., 1998], les fréquences d'apparition peuvent aboutir à une distribution représentant un modèle de la texture. La distribution de Wigner donne de bons résultats dans la modélisation de textures synthétiques et celles de Brodatz [Reed et Wechsler, 1990].

### ➤ La redondance des contours au sein de la texture

Cette méthode est facile à mettre en place mais le résultat est évidemment dépendant du détecteur de contour choisi. Une méthode de classification de textures robuste au bruit, basée sur le détecteur de contours de Canny, est proposée dans [Kjell et Wang, 1991].

## **2.5.2 Les approches structurelles**

Beaucoup moins répandues que les approches statistiques, ces méthodes visent à extraire les primitives de base constituant la texture et un ensemble de règles permettant leur synthèse. Un exemple peut être la description de textures par les fractales [Chaudhuri et al., 1993]. Introduites par [Pentland, 1984], ces approches utilisent la corrélation existant entre l'irrégularité de la texture et sa dimension fractale.

## **2.5.3 Les approches paramétriques**

Basées sur la certitude de l'existence d'un modèle de la texture, ces approches vont chercher à déterminer les paramètres de ce modèle. Ces méthodes présentent l'avantage de pouvoir, après estimation du modèle, synthétiser cette même texture. L'image est alors modélisée comme une distribution de Gibbs ou un champ aléatoire de Markov [Raghu et Yegnanarayana, 1996] [Schroeter et al., 1998]. Issues des mécanismes de la distribution de Gibbs et de la théorie des probabilités de Markov, les MRF (Markov Random Field) permettent de générer aléatoirement des textures régulières ou non (fortement structurées) [Picard, 1991]. Une approche particulière de ces champs de Markov aléatoires, est la GMRF (pour Gaussian MRF). Proposée par [Chellappa et Jain, 1993], elle prend en compte le fait que les niveaux de gris des pixels de l'image suivent globalement une distribution Gaussienne. C'est cette approche qui est la plus utilisée actuellement pour modéliser les textures naturelles ou synthétiques. Son efficacité sur des

images synthétisées à partir des textures de Brodatz a été démontrée dans [Manjunath et Chellappa, 1991].

### 2.6 Évaluation d'une segmentation

En guise de conclusion sur les méthodes de segmentation, on peut émettre les observations suivantes :

- La segmentation « référence » n'est pas forcément unique dans le sens où elle reste très dépendante de la personne qui la réalise.
- La multiplicité des méthodes de segmentation d'images nous donne une multitude de résultats pouvant être très différents les uns des autres.
- On peut être confronté à des approches ne donnant pas forcément un résultat reproductible sur deux applications successives. C'est le cas des méthodes basées sur l'utilisation d'heuristiques telles que les algorithmes évolutionnaires. Elles proposent à chaque application une solution, pouvant être différente, mais proche de la solution optimale sans forcément l'atteindre.

De manière générale, quantifier la véracité du résultat reste quelque chose de très délicat. La mesure de la qualité du résultat est souvent observateur-dépendant mais pas seulement ; un même observateur peut aussi avoir, sur un même résultat, des analyses différentes lorsqu'elles sont espacées dans le temps.

Cette disparité, quant à l'appréciation de chacun, sur un résultat de segmentation et sur la référence, amène la nécessité d'une quantification automatisée des résultats que nous pourrions qualifier d'objective. Pour cela nous regroupons les approches en deux groupes : les approches qualifiées d'automatiques renvoyant une valeur quantitative par un critère spécifique (souvent basé sur les statistiques calculées sur chaque région, frontière...) ; les approches dites supervisées, dans lesquelles le résultat est confronté à une vérité terrain fournie par les experts.

Dans [Philipp-Foliguet et Guigues, 2005a] et [Chabrier, 2005], les auteurs proposent un panel des méthodes d'évaluation regroupées sous ces deux groupes : les approches supervisées et les approches non supervisées. [Chabrier, 2005] fait alors une légère différence en introduisant un troisième groupe appelé « approches génériques » correspondant aux méthodes applicables dans les deux cas (approche supervisée et non supervisée).

#### 2.6.1 Évaluation supervisée

Les résultats obtenus par l'application de diverses méthodes de segmentation sont alors confrontés à la connaissance *a priori* que l'on a de l'image : vérité terrain ou éléments connus. La vérité terrain peut être obtenue soit de façon objective (image synthétique) ou de façon subjective (proposition effectuée par un expert). Dans le cas d'une vérité terrain

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

exprimée par un expert, il est essentiel d'avoir une idée sur l'indice de confiance que l'on peut assigner à un tel résultat.

### 2.6.1.1 Évaluation avec segmentation de référence objective

On discerne différentes approches selon que l'on soit confronté à l'évaluation d'une segmentation en contours ou en régions.

#### 2.6.1.1.1 Évaluation de segmentation en contours

Remarque :

Pour plus de clarté, nous noterons dans cette section :

- \_ A le nombre de pixels de l'image initiale :  $A = \text{card}(\text{Image})$ .
- \_  $\text{Nb}(R_j)$  le nombre de régions distinctes du résultat de segmentation  $R_j$ .

➤ Les mesures empiriques de sur et sous échantillonnage

On distingue habituellement trois types d'erreurs :

- les erreurs de sur segmentation (pixels de la frontière proposée  $F_p$  par la méthode n'appartenant pas à la frontière de la vérité terrain  $F_v$ ) ;

$$\text{ErreurSurDetection}(F_p, F_v) = \frac{\text{card}(F_p \setminus F_v)}{A - \text{card}(F_v)}$$

- les erreurs de sous segmentation (correspondant aux pixels de la frontière non retrouvés par la segmentation à évaluer) ;

$$\text{ErreurSousDetection}(F_p, F_v) = \frac{\text{card}(F_v \setminus F_p)}{\text{card}(F_v)}$$

- les erreurs de localisation (ratio entre les mauvaises détections, éléments sur et sous-détections, et le nombre d'éléments de l'image) :

$$\text{ErreurLoc}(F_p, F_v) = \frac{\text{card}((F_v \setminus F_p) \cup (F_p \setminus F_v))}{A}$$

Un calcul d'indice prenant en compte l'ensemble de ces types d'erreur permet de donner une mesure globale de la qualité du résultat à évaluer.

➤ Les mesures de distance entre le résultat et la référence

Une autre approche intuitive de l'évaluation d'un résultat de segmentation correspond à la mesure d'une distance entre la segmentation à évaluer et la vérité terrain. Les mesures de distance usuelles telles que l'erreur quadratique moyenne [Coquin et al., 1997] ou encore un calcul de distance dans l'espace de Fourier [Wilson et al., 1997] peuvent être remplacées par des mesures de distance basées sur une analyse de probabilités [Bhattacharya, 1967] [Basseville, 1989]. Ces méthodes, n'intégrant pas d'information sur la localisation des pixels au sein de l'image, ne sont pas robustes aux légères variations de position d'un objet entre le résultat et la vérité terrain.

## 2.6 Évaluation d'une segmentation

Baddeley propose l'utilisation d'une variante de la distance de Hausdorff pour l'analyse des images binaires dans un premier temps [Baddeley, 1992] puis pour les images en niveaux de gris [Wilson et al., 1997] :

$$DistBaddeley(F_V, F_P) = \max_{(i,j) \in (F_V \cup F_P)} (\max(d((i,j), F_V), d((i,j), F_P)))$$

$$\text{Avec } d(x, F) = \min_{y \in F} d(x, y).$$

Cette méthode présente l'avantage de prendre en compte l'intensité du pixel et sa position au sein de l'image. Cette distance a été reprise dans bon nombre d'approches pour mesurer la différence entre deux images en niveaux de gris [Zamperoni et Starovoitov, 1996] [Coquin et Bolon, 2001] avant d'être étendue aux images couleur [Coquin et al., 2002].

### ➤ L'utilisation de données topologiques

[Pratt et al., 1978] propose une mesure empirique de comparaison entre une carte de frontières à évaluer ( $F_P$ ) et une carte de frontières de référence ( $F_V$ ).

$$Mesure\_pratt(F_P, F_V) = \frac{1}{\max(\text{card}(F_P), \text{card}(F_V))} \sum_{i=1}^{\text{card}(F_P)} \frac{1}{1 + \alpha d^2(F_P(i), F_V)}$$

Avec  $\alpha$  une constante (positive pour vérifier à coup sûr la contrainte) permettant de conserver la mesure de Pratt dans l'intervalle  $[0 ; 1]$ .

Cette mesure, couramment appelée « Figure of Merit », est l'une des plus utilisées dans la littérature. Elle présente cependant quelques inconvénients : elle est asymétrique et sensible à la sur-détection.

Une autre approche dans l'évaluation de segmentation par contours, est proposée par Odet [Odet et al., 2002]. Ils proposent l'utilisation d'une mesure de divergence entre le résultat et la vérité terrain. La particularité se situe dans la mesure ; elle offre la possibilité d'évaluer divers niveaux d'erreurs de segmentation binaire. Elle est généralement utilisée dans un cas d'évaluation d'un résultat présentant un faible écart type par rapport à la vérité terrain. La mesure globale se base sur le calcul de quatre indices :

- la divergence entre les pixels sur détectés et la frontière de référence

$$ODI_n = \frac{1}{\text{card}(F_P \setminus F_V)} * \sum_{i=1}^{\text{card}(F_P \setminus F_V)} \left( \frac{d_0(i)}{d_{TH}} \right)$$

- la divergence entre les pixels sur détectés et la frontière de référence mais en prenant en compte la localisation du pixel sur détecté (divergence positive ou négative d'un pixel donné).

$$ODP_n = \frac{1}{\text{card}(F_P \setminus F_V)} * \sum_{i=1}^{\text{card}(F_P \setminus F_V)} \left( \frac{d_0(i)}{d_{TH}} \right) * \text{sign}(i, F_V)$$

- la divergence entre les pixels sous détectés et la frontière du résultat de segmentation à évaluer.

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

$$UDI_n = \frac{1}{\text{card}(F_V \setminus F_P)} * \sum_{i=1}^{\text{card}(F_V \setminus F_P)} \left( \frac{d_u(i)}{d_{TH}} \right)$$

- la divergence entre les pixels sous détectés et la frontière du résultat de segmentation à évaluer avec prise en compte de la localisation relative du pixel sous détecté.

$$UDP_n = \frac{1}{\text{card}(F_V \setminus F_P)} * \sum_{i=1}^{\text{card}(F_V \setminus F_P)} \left( \frac{d_u(i)}{d_{TH}} \right) * \text{sign}(i, F_P)$$

Avec :

- \_  $d_0(i)$ , la distance entre le point  $i$  de la segmentation ( $F_P$ ) à évaluer et le point le plus proche de la segmentation de référence ( $F_V$ ).
- \_  $d_u(i)$ , la distance entre un point non détecté de  $F_V$  et le point le plus proche de la segmentation à évaluer ( $F_P$ ).
- \_  $d_{TH}$ , une distance de saturation (seuil de détection d'un pixel de la frontière).
- \_  $\text{sign}(x, F_P)$ , une fonction retournant +1 ou -1 selon que  $x$  se trouve à droite ou à gauche du contour le plus proche dans  $F_P$ . Le sens de parcours et les notions de gauche ou droite du contour sont choisis arbitrairement avant les calculs des divers indices.

Toutes ces valeurs sont normalisées afin de pouvoir les comparer entre elles.

➤ L'analyse multi critères

Partant du principe qu'une segmentation de bonne qualité doit avoir des frontières très proches de la référence, [Correia et Pereira, 2000] utilisent des critères spatio-temporels pour l'évaluation de segmentations dans une séquence vidéo. Lorsqu'il n'y a pas exactement superposition entre les frontières à évaluer et la référence, un ensemble de propriétés peuvent être déduites. Il s'agit des similarités :

- de formes (prenant en compte le nombre de pixels mal placés ainsi que leurs distances par rapport à la référence pour calculer la fidélité de la forme de l'objet)
- géométriques (taille, position, combinaison d'élongation) entre le résultat et la référence
- des contenus des frontières (obtenu par l'application de deux détecteurs de contours dont celui de Sobel).
- statistiques des données entre les frontières à évaluer et celles de la référence.

La mesure de similarité globale peut alors être obtenue par combinaison linéaire de ces quatre indices (avec un poids généralement plus important pour la fidélité de formes) :

$$\text{Mesure\_Correia} = \alpha * \text{Sim}_{\text{Formes}} + \beta * \text{Sim}_{\text{Géométrique}} + \chi * \text{Sim}_{\text{Frontières}} + \delta * \text{Sim}_{\text{Statistiques}}$$

### 2.6.1.1.2 Évaluation de segmentation en régions

Les mesures d'indices présentées par la suite ne sont qu'un panel non exhaustif de ce que l'on peut trouver dans la littérature. Nous avons décidé de reprendre ici les indices les plus communément utilisés.

Remarque :

Pour plus de clarté, nous noterons dans cette section :

- \_  $A$ , le nombre de pixels de l'image initiale :  $A = \text{card}(\text{Image})$ .
- \_  $R_i$ , un résultat de segmentation en régions.
- \_  $R_{ij}$ , la  $j^{\text{ième}}$  région du résultat  $R_i$ .
- \_  $Nb(R_j)$ , le nombre de régions distinctes du résultat de segmentation  $R_j$ .
- \_  $V$ , la segmentation en régions de référence

➤ La mesure de Yasnoff

Cet indice permet de prendre en compte non plus seulement la proportion de pixels mal placés mais aussi la distance ( $d$ ) qui les sépare de la région à laquelle ils appartiennent dans la région de référence (appartenant à la vérité terrain). L'indice peut alors s'écrire :

$$\text{Mesure de Yasnoff} : (100/A) \sqrt{\sum_i d^2(i)}$$

Bien évidemment, le calcul de cet indice nécessite de connaître pour chaque classe, région, du résultat de segmentation, la classe qui lui correspond dans la vérité terrain. Le calcul de l'indicateur étant fondé sur l'erreur de localisation (pixel mal placé), proportionnellement à la distance séparant ce pixel mal placé de la région de référence, génère un problème d'analyse. Un certain nombre de configurations aboutissant à la même mesure d'erreur, il devient difficile de différencier un pixel isolé d'un pixel mal placé.

➤ La mesure de Vinet

Bien que la présence d'une vérité terrain ne soit pas nécessaire à son application, cette mesure est souvent utilisée dans un cadre de segmentation supervisée avec connaissance *a priori* du résultat. Le principe est de générer un couplage optimal des différentes régions des deux segmentations à évaluer. Un appariement biunivoque entre régions au sens du recouvrement maximal est alors appliqué. Soient  $N$ , le nombre de couples de régions et  $C_i$  les recouvrements de chacun des couples. Vinet [Vinet, 1991] déduit alors un calcul de dissimilarité globale de l'image, indice repris dans [Cocquerez et Philipp, 1995] pour comparer des images monochromes texturées et bruitées :

$$\text{Mesure de dissimilarité globale de Vinet} : 1 - (1/A) \times \sum_{i=1}^N \text{card}(C_i)$$

Cet indice, facile à mettre en œuvre, ne permet tout de même pas de prendre en compte toute l'information et privilégie globalement les grandes régions

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

(de probabilités de recouvrement spatial maximales, bien plus importantes que pour les petites régions).

➤ La mesure de Martin

C'est une mesure permettant d'évaluer, à partir d'une référence (vérité terrain ou autre segmentation), la pertinence d'un résultat de segmentation. Soient, pour chaque pixel de l'image,  $V_p$  la région incluant le pixel  $p$  dans la vérité terrain et  $R_{ip}$ , la région incluant le pixel  $p$  dans la segmentation  $i$  à évaluer. Le calcul de la mesure se déduit de deux calculs d'erreur :

- une erreur du résultat de segmentation par rapport à la vérité terrain :

$$Erreur1(p) = \frac{\text{card}(R_{ip}) - \text{card}(V_p \cap R_{ip})}{\text{card}(R_{ip})}$$

- une erreur de la vérité terrain par rapport au résultat de segmentation :

$$Erreur2(p) = \frac{\text{card}(V_p) - \text{card}(V_p \cap R_{ip})}{\text{card}(V_p)}$$

La dissimilarité entre les deux segmentations peut alors s'exprimer au choix par :

- le calcul d'une erreur de cohérence locale.

$$\text{Première mesure de Martin : } (1/A) \times \sum_p \min(Erreur1(p), Erreur2(p))$$

- le calcul d'une erreur de cohérence globale (plus sévère).

$$\text{Deuxième mesure de Martin : } (1/A) \times \min\left(\sum_p Erreur1(p), \sum_p Erreur2(p)\right)$$

➤ La mesure de Kara-Falah

Extension de la mesure proposée par Baddeley, cette mesure quantifie la dissimilarité existant entre deux segmentations en régions  $R_1$  et  $R_2$ .

$$\text{Mesure}_Kara - Falah = \left[ \frac{1}{\text{card}(X)} \sum_{x \in X} |f_{R_1, R_2}(x)|^p \right]^{\frac{1}{p}}$$

Avec :

-  $X$ , le support commun aux deux résultats de segmentation en région :

$$X = \bigcup_{i=1}^{Nb(R_1)} (R_{1i} \cap R_{2i})$$

-  $p$ , un entier positif ;

$$f_{R_1, R_2}(x) = \sum_{i=1}^{Nb(R_1)} d(x, R_{1i}) - \sum_{j=1}^{Nb(R_2)} d(x, R_{2j}) - (Nb(R_1) - Nb(R_2)) * c$$

-  $d$  une distance bornée de borne supérieure  $c$  définie comme  $\lim_{t \rightarrow \infty} fct(t)$  avec

$fct(t)$  une fonction continue définie par l'utilisateur.

La particularité de la méthode réside dans l'utilisation d'une distance bornée entre un pixel et une région quelconque de l'image segmentée. De plus, du fait de prendre en compte la localisation d'un pixel mal placé au sein du résultat, la méthode est relativement plus robuste au bruit. Un inconvénient cependant : le temps de calcul important afin d'obtenir la mesure.

### 2.6.1.2 Évaluation avec segmentation de référence subjective

Ces méthodes permettent d'évaluer le résultat de segmentation par rapport à un ensemble de références proposées. On se place alors dans le cadre d'une vérité terrain inconnue et d'une référence subjective, présentant souvent un degré d'incertitude.

#### ➤ Utilisation des « vrais/faux » « positifs/négatifs »

Dans [Bowyer, 2001], l'auteur propose de partitionner la vérité terrain (synthèse des propositions de segmentation) en trois classes : les pixels appartenant réellement à une frontière (dans toutes les segmentations), les pixels n'apparaissant jamais aux frontières, et les pixels dont on ne sait rien. Il décompose alors l'ensemble des pixels de la segmentation à évaluer en trois groupes :

- Les pixels « vrais positifs » (VP), correspondant aux pixels des frontières du résultat à évaluer appartenant aussi aux frontières de la vérité terrain.
- Les pixels « faux positifs » (FP), appartenant à une frontière dans le résultat à évaluer mais pas dans la vérité terrain.
- Les pixels, que l'on pourrait qualifier de neutres, n'appartenant à aucune des deux catégories précédentes.

À partir de ces ensembles, Bowyer utilise les courbes ROC (Receiver Operation Characteristic) pour rechercher les jeux de paramètres, du détecteur de contours choisi, maximisant le couple « vrais positifs » et « faux positifs ». Il obtient au final une courbe ROC moyenne correspondant à l'évaluation moyenne du détecteur de contours.

[Shufelt, 1999] reprend les notions de « vrais positifs » et « faux positifs » pour y ajouter deux autres notions :

- Les pixels « vrais négatifs » (VN), correspondant aux pixels des frontières du résultat à évaluer n'appartenant pas aux frontières de la vérité terrain.
- Les pixels « faux négatifs » (FN), appartenant à une frontière dans la vérité terrain mais pas dans la carte des frontières à évaluer.

De ces quatre notions, il mesure trois indices.

\_ Le taux de bonnes détections :  $\frac{100 * VP}{VP + FN}$

\_ Le facteur d'embranchement :  $\frac{FP}{VP}$

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

\_ Le pourcentage de qualité :  $\frac{100*VP}{VP + FN + VP}$

Une segmentation est alors évaluée en fonction de ces trois mesures. Cette évaluation, basée uniquement sur le dénombrement de pixels, présente l'inconvénient de ne pas prendre en considération d'information spatiale (pas de calcul de distance entre les frontières à évaluer et celles de la référence).

[Heipke et al., 1997] reprend les indices de Shufelt pour quantifier la qualité de méthode de segmentation de routes. Il définit 6 mesures de performance.

\_ L'exhaustivité  $\in [0 ; 1]$  estimée par:  $\frac{VP}{VP + FN}$

\_ L'état correct  $\in [0 ; 1]$  :  $\frac{VP}{VP + FP}$

\_ La qualité  $\in [0 ; 1]$  :  $\frac{VP}{VP + FP + FN}$

\_ La redondance  $\in [0 ; \infty]$  :  $\frac{VP - lr}{VP}$  avec  $lr$  la longueur de la référence

\_ Une distance (entre le résultat et la référence)  $\in [0 ; l_b]$ :

$$\sqrt{\frac{\sum_{i=1}^l (d^2(extr_i ; ref))}{l}}$$

avec  $l_b$ , la largeur de la bande, à paramétrer avant le début de l'évaluation, et  $d^2(extr_i ; ref)$ , la distance la plus faible entre la  $i^{\text{ème}}$  composante de la région à évaluer  $extr_i$  et celles de la référence.

\_ La statistique des trous : le nombre de trous par unité de longueur

$\frac{\text{nbre\_de\_trous}}{\text{longueur\_référence}}$  et la longueur moyenne des trous =  $\frac{\sum_{i=1}^n l_i}{\text{nbre\_de\_trous}}$  avec

$l_i$ , la longueur du  $i^{\text{ème}}$  trou.

Afin de combler la non prise en compte de critères spatiaux, [Letournel, 2002] propose un autre critère d'évaluation. Basée sur une évaluation humaine de résultats de segmentation, cette approche a permis de sélectionner les attributs pertinents dans l'extraction de bâtiments d'une image aérienne : l'indice d'allongement, l'uniformité, la régularité des frontières, le contraste. Les critères retenus sont ceux offrant un résultat de segmentation proche des résultats de segmentation exprimés par les experts. Un résultat global de l'évaluation est alors obtenu par combinaison des différentes mesures.

➤ Les approches psychovisuelles

En raison du fait qu'une vérité terrain absolue soit souvent difficile, voire impossible à obtenir, [Heath et al., 1996] propose une évaluation basée sur le

## 2.6 Évaluation d'une segmentation

jugement de divers observateurs et leurs modes d'obtention. Cette évaluation, nécessitant l'intervention humaine, inclut donc implicitement un degré d'incertitude ; incertitude levée par la statistique des jugements (nombre élevé d'interprétations). Cette méthode a l'avantage d'être robuste à l'analyse des images naturelles contrairement à d'autres méthodes robustes uniquement pour le traitement d'images synthétiques. Il explique ce phénomène par le fait qu'une image synthétique ne peut représenter la complexité de la nature. La méthode proposée a été utilisée dans [Heath et al., 1996] pour évaluer la performance de quatre détecteurs de contours : Canny, Sobel, Nalwa-Binford et Sarkar-Boyer. L'algorithme se divise en deux parties : la recherche des paramètres optimaux de chaque méthode puis la classification des résultats obtenus par chacune des méthodes en utilisant le jeu de paramètres optimaux. Il distingue alors trois observations :

- Il existe une différence significative entre les diverses méthodes de segmentation.
- Les paramètres optimaux d'une méthode de segmentation sont fortement image-dépendants. Il préconise alors, pour l'analyse d'une image inconnue, la recherche de ces paramètres par une méthode basée sur les caractéristiques de l'image (contrairement à ce que pourrait laisser penser l'utilisation de méthodes de segmentation locales).
- Les méthodes de segmentation proposées sont plus ou moins efficaces selon le type d'image analysé. En d'autres termes, il ne devrait pas exister de méthode de segmentation efficace pour tous types d'images. Il devient alors nécessaire d'identifier le contexte dans lequel la segmentation en contour doit être utilisée pour rendre cette segmentation optimale.

[Shaffrey et al., 2002] présente une méthode similaire mais qui, contrairement à l'approche de Heath, ne part pas du principe de segmenter un objet précis de la scène mais l'image dans sa globalité. Développée de la même façon que Heath, son approche se subdivise en une partie optimisation de paramètres des méthodes à évaluer puis une partie classification des résultats obtenus pour ces diverses méthodes. Chaque phase d'évaluation s'effectue en proposant à un juge deux segmentations visuelles à classer. Ces phases sont chronométrées de façon à prendre en compte l'incertitude dans le choix (un choix difficile engendrant l'hésitation). Il déduit de ces expériences deux indices normalisés : un « hard » indiquant l'image choisie (+1 ou -1) et un indice « soft » prenant en compte le temps nécessaire à la décision. Il exprime ensuite un indice global, combinaison des deux indices : « hard » et « soft ».

[Arbelaez, 2005] présente une implémentation particulière de la méthode de Précision-Rappel pour mesurer la performance d'algorithmes de segmentation en tant que détecteur de contours. Il évalue notamment ses méthodes de segmentation d'images basées sur des mesures de distance (mesures d'énergies le long de chemins de l'image ou encore sur des ultramétriques). Sa méthode

## État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

d'évaluation fait écho aux travaux de [Martin et al., 2004]. Dans [Martin et al., 2004] les auteurs utilisent un ensemble de vérités terrain aussi bien pour la calcul de leur modèle de frontière local que pour l'étape d'évaluation de ce modèle. La première phase, appliquée sur un ensemble important d'images (200) leur permet de déterminer, mais aussi d'optimiser, les différents paramètres (luminance, couleur, propriétés des textures) à combiner entre eux pour atteindre une modèle de segmentation optimal, adapté au type d'image à traiter (type conditionné par la phase d'apprentissage). La phase de validation s'effectue elle aussi via l'utilisation d'une famille de vérités terrain. Basée sur la mesure de la F-mesure [Van Rijsbergen, 1979] directement issue du calcul du couple Précision / Rappel, elle permet d'estimer la cohérence du résultat obtenu avec les tracés fournis par les experts. Cet indice permet de plus l'estimation de la cohérence entre les diverses vérités terrains (tracés d'experts). [Arbelaez, 2005] met alors en avant la bonne cohérence des résultats d'« Humains » et émet l'idée d'une similarité d'analyse liée à l'organisation perceptuelle identique des images naturelles au sein d'un groupe d'Humains.

L'approche psychovisuelle permet ainsi d'effectuer une évaluation sur des images pour lesquelles la vérité terrain est difficile à obtenir. Cette particularité rend l'automatisation de l'approche impossible et la mise en place des évaluations difficiles à réaliser (disponibilités des experts). Toutefois, cette approche permettrait de valider d'autres approches automatiques d'évaluation.

### **2.6.2 Évaluation non supervisée**

Ces méthodes d'évaluation permettent une comparaison de résultats sans avoir aucune connaissance *a priori* de la vérité terrain. Selon la méthode de segmentation choisie, approche contour ou région, les méthodes d'évaluation ne seront pas les mêmes. C'est pourquoi, nous proposons par la suite de différencier l'état de l'art en deux sections : l'évaluation non supervisée des segmentations en régions et l'évaluation non supervisée des segmentations en contour.

#### **2.6.2.1 Évaluation des méthodes basées régions**

- Mesure de contraste intra-régions

Liée au caractère d'uniformité des régions extraites de la segmentation (uniformité intra région), [Weszka et Rosenfeld, 1978] proposent une mesure d'évaluation basée sur une quantification du bruit. Cette mesure du bruit est obtenue via le calcul de la matrice de co-occurrences des niveaux de gris de l'image. Cette mesure se base sur l'hypothèse que moins la présence de bruit est importante, plus le résultat de segmentation à évaluer doit être bon.

## 2.6 Évaluation d'une segmentation

En partant du même principe d'uniformité des régions du résultat à évaluer, [Levine et Nazif, 1985] proposent une mesure issue de l'uniformité locale à chacune des régions. La mesure d'uniformité globale, basée sur la somme des variances des régions, est alors généralisée. Dans ce cas, un pixel peut être représenté par son intensité mais aussi par tout autre attribut tel que sa couleur ou des paramètres de texture. De plus, afin de donner de l'importance aux grandes et/ou petites régions, chaque région peut être pondérée par son nombre d'éléments. Facilement mis à jour lors des opérations de division/fusion des diverses régions, ce dernier indice, utilisé dans la comparaison de méthodes de seuillage [Sahoo et al., 1988] et de segmentation [Zhang, 1996], s'est révélé peu discriminant.

Reprenant le même principe d'uniformité, Cochran propose un indice de confiance sur l'homogénéité des régions [Cocquerez et Devars, 1985]. Cet indice peut être calculé sur n'importe quel attribut ou ensemble d'attributs des pixels de la région. Une région est alors considérée comme homogène si cet indice de confiance est inférieur à un seuil. Bien évidemment, le résultat de l'évaluation sera fortement dépendant du choix du seuil et des attributs sélectionnés pour la mesure.

### ➤ Mesure inter-régions de Levine et Nazif

[Levine et Nazif, 1985] fournissent un indice calculé sur le contraste inter-régions entre une région donnée et ses voisines (régions ayant une partie de leurs frontières en commun) :  $c_{R_{ki}, R_{kj}} = \frac{|m_i - m_j|}{m_i + m_j}$  avec  $m_i$  la moyenne des niveaux de gris dans la région  $i$  du résultat de segmentation  $k$ .

Cette mesure est rendue possible par l'hypothèse forte que deux régions adjacentes sont par définition différentes en contenu. Les auteurs calculent alors le contraste de chacune des régions de la segmentation avant d'aboutir à un indice de contraste global (après pondération des contrastes obtenus sur chaque région) :

$$c_{R_{ki}} = \sum_{j=1}^N \frac{l_{ij}}{l_i} * c_{R_{ki}, R_{kj}} \text{ et le contraste global} = \frac{\sum_i w_i * c_{R_{ki}}}{\sum_i w_i}$$

Avec :

- \_  $N$ , le nombre de régions adjacentes à la région  $R_{ki}$ .
- \_  $l_i$ , la longueur de la frontière de la région  $R_{ki}$
- \_  $l_{ij}$ , la longueur de la frontière en commun entre les régions  $R_{ki}$  et  $R_{kj}$
- \_  $w_i$ , le poids affecté au contraste de la région  $R_{ki}$ .

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

Cet indice global présente l'avantage de pénaliser la sur-segmentation mais s'est montré non discriminant pour l'analyse d'images texturées.

➤ Mesure inter-intra région de Zéboudj

Cet indice prend en compte à la fois l'uniformité au sein d'une région (contraste intérieur) et la dissimilarité avec les régions voisines (contraste extérieur). Cela est rendu possible par les calculs des contrastes intérieur et extérieur d'une région. Ils sont tous deux basés sur une mesure locale de contraste entre un pixel  $x$  et ses voisins  $V(x)$  (utilisation d'un voisinage).

$$I_i = \frac{1}{\text{card}(R_{ki})} \times \sum_{x \in R_{ki}} \max\{c(x, p), p \in V(x) \cap R_{ki}\}$$

$$E_i = \frac{1}{l_i} \times \sum_{x \in F_{ki}} \max\{c(x, p), p \in V(x), p \notin R_{ki}\}$$

Avec  $c(x, p)$  le contraste entre les deux pixels  $x$  et  $p$ ,  $F_{ki}$  la frontière de la région  $R_{ki}$  de longueur  $l_i = \text{card}(F_{ki})$  et  $R_k$ , le résultat de segmentation.

Le contraste d'une région  $R_{ki}$  découle directement du calcul des ces deux

indices : 
$$C(R_{ki}) = \begin{cases} 1 - \frac{I_i}{E_i} & \text{si } 0 < I_i < E_i \\ E_i & \text{si } I_i = 0 \\ 0 & \text{sinon} \end{cases}$$
 ainsi que la mesure globale :

$$\frac{1}{A} \sum_i \text{card}(R_{ki}) * C(R_{ki})$$

Cette mesure a été testée dans [Cocquerez et Philipp, 1995] pour comparer des résultats de segmentation obtenus sur des images réelles et de synthèse. Elle apparaît ne pas être robuste à l'analyse sur des images texturées et/ou bruitées.

De même, [Rosenberger, 1999] propose un critère permettant d'évaluer une segmentation en  $L$  classes d'une image  $I$ . Ce critère s'appuie sur les maximisations de l'homogénéité des régions (contraste intérieur) et du contraste entre régions (contraste extérieur).

$$C_{\text{intra}}(I_L) = \frac{1}{L} \sum_{i=1}^L \frac{\text{card}(L_i)}{A} * C_{\text{intra}}(L_i) \text{ où } C_{\text{intra}}(L_i) \text{ correspond à la disparité}$$

intra-classe de la classe  $L_i$ .

$$C_{\text{inter}}(I_L) = \frac{1}{L} \sum_{i=1}^L \frac{\text{card}(L_i)}{A} * C_{\text{inter}}(L_i) \text{ où } C_{\text{inter}}(L_i) \text{ correspond à la disparité intra}$$

classe de la classe  $L_i$ .

## 2.6 Évaluation d'une segmentation

Basée sur un calcul d'uniformité des niveaux de gris de chacune des régions du résultat à évaluer, cette approche permet de prendre en compte aussi bien les régions uniformes (un pixel est alors caractérisé par son intensité) que les régions texturées (un pixel est représenté par un ensemble d'attributs de texture). La mesure finale est alors calculée à partir des disparités intra et inter régions ainsi calculées :

$$mesure\_de\_Rosenberger = \frac{C_{intra}(I_L) + 1 - C_{inter}(I_L)}{2}$$

### ➤ Évaluation sur plusieurs critères

Soit un résultat de segmentation  $R_1$ . Le critère de mesure proposé par Liu et Yang [Liu et Yang, 1994] permet de prendre en compte à la fois le nombre, l'intensité moyenne et l'aire des diverses régions obtenues par segmentation d'une image en couleur RGB :

$$Mesure\_Liu = \frac{1}{1000 \times A} \sqrt{Nb(R_1)} \sum_{i=1}^{Nb(R_1)} \frac{e_i^2}{\sqrt{card(R_{1i})}}$$

où  $e_i$  correspond à la somme

des distances euclidiennes entre les vecteurs d'attributs des pixels de la région  $R_{1i}$  et le vecteur attribut attribué à la région  $R_{1i}$ .

Par analogie au système de vision humaine favorisant une détérioration des contours des régions plutôt que la création de nouvelles régions, le critère pénalise la sur-segmentation. Une valeur faible de la mesure indique une segmentation de bonne qualité minimisant le nombre de régions homogènes.

[Borsotti et al., 1998] ont observé que la pénalisation du nombre de régions, dans le critère de Liu, conduit à donner de meilleurs résultats aux segmentations fortement bruitées. Cela reviendrait en effet à évaluer une segmentation proposée sous forme de régions formées par quelques pixels uniquement et donc d'erreur intra-régions très faible. Pour pallier ce problème, Borsotti propose d'ajouter à la mesure de Liu un nouveau terme pénalisant les segmentations proposant un trop grand nombre de régions.

$$Mesure\_Borsotti = \frac{1}{10000 \times A} \sqrt{Nb(R_1)} \sum_{i=1}^{Nb(R_1)} \left( \frac{e_i^2}{1 + \log(card(R_{1i}))} + \left( \frac{Nb\_même\_aire(R_{1i})}{card(R_{1i})} \right)^2 \right)$$

avec  $Nb\_même\_aire(R_{1i})$  le nombre de régions ayant la même aire que  $R_{1i}$ .

Au final, la mesure de Borsotti favorise les segmentations ayant un nombre de régions homogènes limité et l'absence de petites régions (en adéquation avec l'absence de trous préconisée par Haralick et Shapiro). Cependant, le critère de Borsotti devient alors trop contraignant pour les segmentations composées de petites régions et favorise la sous-segmentation. [Glory et al., 2006] propose alors de modifier le critère de Borsotti de façon à ne plus contraindre le nombre de régions. La mesure, divisée en deux termes

État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

contrôlant l'homogénéité des régions et leur nombre, est alors validée sur un ensemble d'images cytologiques.

$$Mesure\_Glory = \frac{\sum_{i=1}^{Nb(R_1)} \frac{e_i^2}{1 + \log(card(R_{l_i}))}}{e^2} + \frac{\sum_{R_k=R_{1min}}^{R_{1max}} \frac{Nb\_meme\_aire(R_k)}{(aire(R_k))^2}}{Nb(R_1)}$$

$$\frac{1}{1 + \log(A)} + 1$$

avec  $R_{1min}$  et  $R_{1max}$  respectivement les régions de plus petite et plus grande aires issues de la segmentation  $R_1$ ,  $e$  le contraste calculé sur toute l'image,  $Nb\_meme\_aire(R_k)$  une fonction fournissant le nombre de régions ayant la même aire que  $R_k$  ; aire renvoyée par la fonction  $aire(R_k)$ .

Une autre approche multicritères, proposée par [Philipp-Foliguet et Guigues, 2005b], considère le problème de segmentation d'image comme un problème de modélisation par morceaux. Chaque région peut être ainsi assimilée à un morceau de l'image. La qualité de la segmentation peut alors être déduite d'une mesure d'énergie globale calculée sur l'ensemble du modèle. Cet indice correspond à la combinaison des mesures d'énergie de complexité (fonction de la longueur du contour) et d'énergie interne (distance entre le modèle et l'image). Un facteur de proportionnalité modulant l'énergie de complexité permet de favoriser l'allure globale des régions (plus ou moins complexes, lisses). Ce critère, très facile à calculer, permet l'évaluation de segmentations d'images aussi bien en niveaux de gris que de manière multispectrale. Il permet, entre autres, l'évaluation de segmentations obtenues sur des images texturées.

### 2.6.2.2 Évaluation des méthodes basées contour

➤ Mesure de Levine et Nazif

[Levine et Nazif, 1985] proposent une évaluation de deux types de frontières. Le calcul du contraste intra-régions permet la détection des frontières des objets alors que le calcul du gradient moyen le long d'une ligne de l'image, permet l'extraction des lignes traversant les objets de l'image.

Soit  $F$  la carte des contours obtenue par application d'une approche contour sur une image  $I$  composée de  $N$  lignes de contour. Associons, à chaque pixel de l'image  $I$ , un vecteur d'attributs calculés localement (attributs de texture, niveau de gris).

La mesure de contraste vis-à-vis d'une ligne  $l_i$  de  $I$  est définie comme :

$$c_{lev}(l_i) = \frac{|c_g(l_i) - c_d(l_i)|}{c_g(l_i) + c_d(l_i)}$$

Avec  $c_g(l_i) = \sum_{R_j \in Wg(l_i)} card(l_i \cap R_j) \bar{a}(R_j)$  et  $c_d(l_i) = \sum_{R_j \in Wd(l_i)} card(l_i \cap R_j) \bar{a}(R_j)$

## 2.6 Évaluation d'une segmentation

$W_g(l_i)$  et  $W_d(l_i)$  correspondent aux régions voisines situées respectivement à gauche et à droite de la frontière  $l_i$  ;  $\bar{a}(R_j)$  correspond à l'attribut moyen calculé sur la région  $R_j$ .

La mesure du gradient moyen des pixels le long d'une ligne  $l_i$  est définie comme :

$$g_{lev}(l_i) = \frac{\bar{G}}{\max_{x \in (R_j \in W(l_i))} (a(x)) - \min_{x \in (R_j \in W(l_i))} (a(x))} \quad \text{où } \bar{G} \text{ et } W \text{ représentent}$$

respectivement le gradient moyen de l'attribut  $a$  calculé sur les pixels de la ligne  $l_i$  et le voisinage de  $l_i$ .

De ces deux indices, [Levine et Nazif, 1985] déduisent un indice de connexité global des frontières à évaluer permettant de mesurer les frontières manquantes.

### ➤ Mesures basées sur la structure des frontières (flou, structure locale)

[Han et Kim, 2002] définissent une distance d'ambiguïté mesurée via une approche floue. Elle permet de quantifier la justesse de la frontière obtenue. La mesure d'ambiguïté globale de la segmentation peut être obtenue via le calcul de trois indices : les ambiguïtés d'existence et de localisation, directement déduites d'une modélisation par approche floue des représentations en contours, et une ambiguïté de disposition représentant une mesure de connexité des différents points des frontières. Cette méthode est utilisée notamment pour la recherche de paramètres optimaux (seuils) pour une méthode de segmentation donnée. Le jeu de paramètres de la méthode qui produit le moins d'erreur d'ambiguïté globale est alors le plus adapté.

Se basant sur la cohérence locale des différentes frontières proposées par la segmentation, [Kitchen et Rosenfeld, 1981] ont proposé une mesure basée sur la cohérence de deux critères caractéristiques : la continuité et l'épaisseur des frontières (frontières générées par un détecteur de frontières). [Tan et al., 1992] ajoutent à cette mesure locale (chaque pixel) sur la carte des frontières  $F$  la prise en compte de trois autres caractéristiques que sont la dissimilarité, la courbure et le nombre de pixels frontière :

$$C_F(i, j) = w_1 C_{\text{Minceur}, F}(i, j) + w_2 C_{\text{Dissimilarité}, F}(i, j) + w_3 C_{\text{Courbure}, F}(i, j) \\ + w_4 C_{\text{Fragmentations}, F}(i, j) + w_5 C_{\text{NbPixelsFrontière}, F}(i, j)$$

Avec  $w_i$  des poids fixés selon l'impact que l'on souhaite donner à tel ou tel critère et  $(i, j)$  les coordonnées du pixel courant.

Cette dernière approche essaie de combiner l'ensemble des caractéristiques afin d'obtenir un résultat acceptable ; la méthode correspond davantage à une heuristique qu'à un modèle mathématique.

### **2.6.3 Discussion sur les méthodes d'évaluation.**

Comme repris dans de nombreux travaux [Chabrier, 2005], [Philipp-Foliguet et Guigues, 2005a], il existe de nombreux critères permettant d'évaluer un résultat de segmentation. Ces critères peuvent être regroupés en familles établies sur le type d'évaluation : avec ou sans vérité terrain et le type d'approche utilisée pour la segmentation : contour ou région. La diversité de ces approches démontre la difficulté de trouver un critère universel et introduit la nécessité de les comparer entre eux [Chabrier, 2005]. La comparaison des diverses méthodes d'évaluation, pourrait permettre à la communauté scientifique de disposer de résultats pouvant orienter les chercheurs vers telle ou telle méthode selon l'application. Toutefois, les résultats de segmentation étant fonction du type d'image traitée ainsi que des valeurs des différents paramètres des méthodes envisagées (seuils, nombre de classes...), la comparaison paraît ardue à effectuer. Pour ce qui nous concerne, nous nous sommes limité, dans ce manuscrit, à l'utilisation d'une comparaison simple du type « rappel et précision » pour évaluer deux résultats de segmentation.

Les divers composants de l'image extraits, nous allons maintenant nous intéresser à leurs caractéristiques. Pour ce faire, nous proposons de faire un bref tour d'horizon des méthodes de représentation, et de modélisation, de courbes que l'on trouve dans la littérature.

## **2.7 Représentation et modélisation des interfaces**

Les courbes, au même titre que les surfaces, sont présentes dans de nombreuses applications. Leur modélisation joue souvent un rôle important dans la compréhension de l'image permettant d'accéder à un niveau de perception plus global. C'est dans cet objectif que sont encore aujourd'hui développées de nombreuses approches. Nous présentons ici un ensemble non exhaustif de méthodes permettant la modélisation de courbes.

### **2.7.1 Les modèles géométriques**

Mises à part les caractéristiques géométriques classiques telles que : l'aire, le périmètre, le diamètre, l'enveloppe convexe..., on utilise souvent en complément, des indices de formes tels que l'allongement, la concavité ou encore le rapport isométrique de la forme étudiée. Bien évidemment, la description de forme n'est généralement pas discriminante (formes de même aire et périmètre pour une allure globale différente). On en vient alors généralement au calcul des moments statistiques permettant une description de la forme de l'objet. Les trois premiers ordres : moyenne, variance et symétrie dans la distribution; permettant ainsi une caractérisation de l'objet traité.

## 2.7 Représentation et modélisation des interfaces

Tous les éléments de description présentés précédemment peuvent être appliqués à une forme quelconque. Nous nous limitons maintenant aux approches permettant de décrire des contours. Mise à part l'approche signature de contours, se limitant à la recherche du centre de gravité de la forme et des distances entre les différents points du contour et lui-même, nous pouvons citer les descripteurs de Fourier et le code de Freeman.

L'ensemble des descripteurs de Fourier permet la caractérisation de la courbe par le calcul des coefficients d'une série de Fourier donnant une bonne estimation de la forme [Bachnou, 1999]. Toutefois, il est souvent nécessaire d'utiliser les descripteurs de Fourier normalisés du contour permettant de rendre les composantes du descripteur de Fourier classique invariantes aux opérations spatiales (rotations, translations). Une autre alternative dans la modélisation d'un signal, peut être donnée par le codage de Freeman. La courbe peut être de plus exprimée sous la forme d'une suite de points tous obtenus à partir des points initiaux (segments de droite entre ces points). Appelée « chain code » en anglais, la courbe est représentée par les coordonnées du point de départ et un ensemble de petits déplacements (codage directionnel sur 3 bits par exemple pour une courbe 8-connexe) permettant de la synthétiser de nouveau.

Une autre approche consiste à étudier la courbure en chaque point du contour de la courbe. [Asada et Brady, 1986] propose une description de la courbe basée sur les variations de courbure de la courbe. [Mokhtarian et Mackworth, 1986] ont montré que les points d'inflexion des courbures obtenues via l'utilisation d'une pyramide Gaussienne peuvent être utilisés pour reconnaître les objets. La limite de cette approche réside dans le cas où la courbe ne présente aucun point d'inflexion. [Dudek et Tsotos, 1997] présentent une méthode permettant la reconnaissance et la représentation de formes basées sur une information multi-échelle de la courbure.

Une autre façon de traiter la question consiste en une analyse morphologique telle que les distributions (intensités, primitives de base...) ou l'analyse granulométrique utilisée pour quantifier l'information présente dans une image à différents niveaux [Bangham et al., 1996]. [Kimia et Siddiqi, 1996] et [Jackway et Deriche, 1996] proposent une méthode mettant en scène différentes étapes de dilatation et d'érosion. [Jang et Chin, 1998] décrivent les différentes représentations obtenues à différentes échelles d'observation via l'utilisation des opérations morphologiques d'ouverture et de fermeture. Ils utilisent pour cela un élément structurant de taille croissante. L'approche de [Leymarie et Levine, 1989] est un peu différente. Les auteurs utilisent des transformations chapeau haut de forme (« top-hat » et « bottom-hat transforms » en anglais) pour analyser la courbure de la courbe à différentes échelles d'observation. Partant du point faible que cette méthode ne permet pas, pour un niveau d'observation donné, de différencier les structures imbriquées, [Jalba et al., 2006] proposent alors une amélioration. Basée sur

## État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

deux représentations à des échelles différentes correspondant à l'application des deux transformées chapeau haut de forme (bas et haut), une extraction des caractéristiques de la courbe est effectuée à chacun des deux niveaux. Le vecteur d'attribut résultant est alors utilisé comme descripteur de la forme et permet ainsi son identification et sa synthèse. Dans un autre article, [Jalba et al., 2004] présentent l'utilité des transformées chapeau haut de forme pour la classification de textures.

### **2.7.2 La modélisation polygonale**

Les modèles polygonaux consistent à ne retenir que quelques points de l'interface et à approximer la courbe entre deux points consécutifs par un segment de droite. Beaucoup d'approches ont été développées dans la littérature pour résoudre ce problème d'approximation. Citons, parmi elles, les méthodes de divisions/fusions [Pavlidis et Horowitz, 1974] [Wall et Danielsson, 1984], les méthodes utilisant la transformée de Hough [Gupta et al., 1993] les méthodes basées sur l'organisation perceptuelle [Hu, 2002], les méthodes recherchant les points dominants de la courbe (point présentant de hautes valeurs de courbure) [Teh et Chin, 1989] [Marji et Siy, 2003], celles utilisant les réseaux de neurones de Hopfield [Chung et al., 1994], celles utilisant la programmation dynamique [Horng et Li, 2002] puis celles utilisant une heuristique, les algorithmes génétiques par exemple, pour trouver une solution optimale au problème [Adams et Bischof, 1994] [Huang et Sun, 1999]. Pour ce dernier cas, il existe aussi une approche visant à approcher la courbe à modéliser entre deux points consécutifs par un arc de cercle [Sarkar et al., 2003].

Malheureusement, les polynômes classiques ne se prêtent pas bien à la modélisation de toutes formes de courbes. En effet, même s'ils demeurent un choix classique dans la modélisation de la relation entre les variables de sortie et les co-variables continues, ils manquent souvent de souplesse. Leur plus gros désavantage réside dans le choix du degré du polynôme envisagé. En effet, un degré trop faible ne permet pas un ajustement correct aux données alors qu'un polynôme de degré trop élevé souffrira d'un mauvais ajustement aux extrémités et/ou un ajustement en forme de vague. Pour essayer de solutionner le problème, [Royston et Altman, 1994] introduisent les polynômes de degrés non entiers : les polynômes fractionnaires. Ils sont actuellement utilisés dans de nombreux travaux tels que ceux de [Robert-Granié et al., 2002].

### **2.7.3 Les modèles Paramétriques**

Si les modèles polygonaux décrits précédemment sont des modèles approxinant la courbe par des morceaux linéaires (1<sup>er</sup> degré), ils nécessitent donc un nombre de points important pour suivre correctement le signal à estimer (besoin d'un seuil de précision). Pour limiter le nombre de points nécessaires à la modélisation tout en conservant une bonne approximation, il

## 2.7 Représentation et modélisation des interfaces

faut alors passer à des modèles de degrés supérieurs. Les modèles paramétriques semblent alors être de bons candidats à la modélisation. On utilise généralement une famille de modèles cubiques (de degré 3) englobant les courbes de Bézier, les Splines et les Catmull-Rom. Les deux premières approches permettent une approximation du signal alors que les Catmull-Rom correspondent plus à une interpolation. Nous présenterons uniquement les deux premières approches (courbes de Bézier et Splines) dans ce paragraphe.

### Les courbes de Bézier

Introduites en 1962 par Pierre Bézier pour la conception de nouvelles pièces automobiles, les courbes de Bézier sont aujourd'hui présentes dans de nombreuses applications de rendu 3D et de synthèse d'images. Défini par un ensemble de polynômes de Bernstein et un ensemble de points de contrôle, le contrôle de la courbe est global. Une modification des coordonnées d'un point de contrôle engendre une modification de la courbe dans sa globalité. [Romaniuk et al., 2003] présentent une optimisation de ces courbes de Bézier pour l'approximation de courbes. Pour un grand nombre de points de contrôle, on utilise généralement des courbes de Bézier cubiques (4 points de contrôle) que l'on colle bout à bout. [Romaniuk et al., 2003] proposent alors une optimisation des raccords entre ces points de jonction.

### Les B-Splines

Généralisation des courbes de Bézier, les B-splines sont des courbes polynomiales cubiques approximant un nombre quelconque de points de contrôle. Contrairement aux courbes de Bézier, une modification d'un des points de contrôle de la B-spline engendre une modification locale de la courbe (un point de contrôle affectant 4 segments de courbe). Ainsi, il devient très simple d'ajouter, [Barry et Goldman, 1988], ou supprimer, [Lyche et Mørken, 1987], un point de contrôle. Visant à optimiser les coordonnées des points de contrôle et donc l'approximation finale, d'autres méthodes ont été développées [Razdan, 1999] [Huang et al., 2005] [Li et al., 2005a]. Généralisation des B-splines, les NURBs (Non-Uniform Rational B-Spline), définies dans les années 1950, sont utilisées pour représenter de manière plus précise les objets géométriques. L'ensemble des fonctions rationnelles étant plus important que celui des fonctions polynomiales, les NURBS donnent souvent de meilleurs résultats que les B-splines dont elles sont issues. Dans [Laurent-Gengoux et Mekhilef, 1993] et [Randrianarivony et Brunnett, 2002], les auteurs présentent des méthodes visant à optimiser l'approximation de courbes par des NURBS en jouant sur le positionnement des points de contrôle.

## 2.7.4 Les modèles multi-échelles

### 2.7.4.1 Les modèles utilisant les ondelettes

Influencées par l'approche émergente des ondelettes, beaucoup d'approches, utilisant cet outil, ont été développées. [Chuang et Kuo, 1996] ont utilisé des

## État de l'art : segmentation, évaluation puis caractérisation des composants d'une image.

ondelettes orthogonales et bi-orthogonales afin d'étudier les propriétés de la courbe à différentes échelles de représentation.

Contrairement aux B-Splines hiérarchiques [Forsey et Bartels, 1988] qui sont une sur représentation de la courbe, surface, étudiée, [Chui, 1992] définit la notion de « B-spline wavelet » agissant sur une réelle représentation multi résolution. Cette méthode, reprise dans de nombreux travaux [Wang et Lee, 1999] [Lyche et al., 2001] [Kazinnik et Elber, 1997] [Sweldens, 1997] [Li et al., 2005b], consiste à étudier l'évolution des B-Splines approximant la courbe étudiée à différents niveaux de représentation. Cette approche permet de tirer parti des B-Splines et des ondelettes simultanément.

### **2.7.4.2 Le modèle fractal**

Tant avec des modèles paramétriques polygonaux qu'avec l'utilisation de primitives géométriques, la modélisation de courbes naturelles (nuage dans le ciel ; les feuilles...) reste délicate à réaliser. Il est donc nécessaire d'introduire un nouveau type de modèle permettant de prendre en compte ces structures naturelles : les modèles fractals. Proposés à l'origine par Mandelbrot [Mandelbrot, 1982], ces modèles permettent de modéliser les formes irrégulières présentant une certaine répétition tout en conservant la même complexité. Les approches fractales développées depuis sont souvent centrées sur cette propriété « d'auto similarité » correspondant à l'invariance structurelle pour différentes échelles d'observation. Ces modèles cherchent alors les paramètres des IFS (Iterated Function Systems) dont l'attracteur approche le mieux possible la courbe à modéliser [Guérin et al., 2002] [Portefaix et al., 2003] [Barnsley, 1986].

## **2.8 Conclusion sur l'état de l'art**

Nous venons de présenter un état de l'art non exhaustif des méthodes de segmentation d'images, d'évaluation des résultats de segmentation et, de plus, nous avons indiqué l'état actuel de la recherche sur la modélisation d'interfaces.

La diversité des méthodes de segmentation tout comme la diversité des méthodes d'évaluation nous laissent penser qu'une méthode générique de segmentation tout comme une méthode générique d'évaluation, capables de traiter l'ensemble des cas, n'existent pas. Les nombreux travaux sur les optimisations des diverses méthodes mentionnées par recherche de paramètres optimaux (seuil, échelle d'observation, fonction coût à minimiser...) expriment la difficulté d'évaluer une méthode de segmentation pour laquelle le résultat optimal n'est pas forcément atteint.

Nous proposons donc à travers les chapitres suivants une méthode de caractérisation des diverses interfaces présentes dans l'image sans développer une approche réelle de segmentation. Toutefois, le découpage de l'image en

## 2.8 Conclusion sur l'état de l'art

régions grossières faisant partie de la méthodologie adoptée, nous comparerons les résultats avec d'autres issus de la littérature. Pour l'évaluation, tout comme le laisse présager la recrudescence de méthodes psychovisuelles, les méthodes supervisées permettant une meilleure comparaison seront à privilégier. On palliera alors la subjectivité « humaine » de la vérité terrain fournie par une étude statistique sur les propositions des experts médicaux.

En ce qui concerne la caractérisation des objets constituant l'image, nous pouvons différencier d'une part les milieux (régions) et d'autre part les interfaces (courbes). Bien que pour les milieux, une modélisation par utilisation de champs de Markov puisse donner de bons résultats, le temps nécessaire aux calculs des différentes probabilités conditionnelles est pénalisant et nous oriente vers le choix de la méthode proposée par Li-Yi Wei [Wei, 2001] conservant une analyse locale de la texture. Pour les interfaces, le caractère naturel des images échographiques, nous fait privilégier une caractérisation fractale.

## Chapitre 3

### **3 Appréhension quantitative et qualitative des objets**

---

Dans le cadre de l'aide au diagnostic médical, il y a un intérêt à définir l'interface séparant des milieux texturés. Pour caractériser cette interface, nous nous appuyons sur une méthode floue permettant, via la modification de l'échelle d'observation, d'extraire une zone de transition grossière incluant l'interface et séparant deux milieux de l'image. Pour définir la complexité de l'objet recherché, nous nous basons sur le calcul de sa dimension fractale. Cette approche est d'abord validée sur diverses images synthétisées, donc contenant des interfaces de dimensions connues, puis appliquée à des images ultrasonores à deux milieux se rapprochant ainsi du contexte de travail : la télé-échographie.

---



### **3.1 Introduction**

La diversité des techniques de segmentation conduit à la certitude de la non unicité d'une méthode pour analyser toutes les catégories d'images. Les différentes méthodes présentées au chapitre 2 (segmentation par recherche de contours, de régions ou encore par analyse de texture), ont bien souvent une efficacité limitée sur un type d'image donné.

Il n'est pas rare dans le contexte des images ultrasonores, que le flou intrinsèque, assimilé à du bruit, amplifié par la chaîne d'acquisition et de transfert de données sur le réseau, rende difficile l'application des techniques usuelles de segmentation. Pour appuyer cette idée, on peut citer l'exemple de l'échographie 3D. Encore aujourd'hui, les méthodes automatiques de segmentation des coupes restent en compétition avec la sélection manuelle des contours des différents organes présents au sein de l'image réalisée par l'expert.

Excepté pour les images échographiques fœtales, dans lesquelles le fort contraste entre le liquide amniotique et les tissus fœtaux facilite le traitement, la segmentation automatique est très souvent réduite à la superposition sur l'image d'un modèle déformable de l'organe étudié [Cohen, 1997], nécessitant ainsi une connaissance *a priori* de l'environnement. Toutefois, le filtre BLTP (Binarize, Low-pass, Threshold, and Propagate) proposé par Sakas [Sakas et Walter, 1995] semble donner de bons résultats dans de nombreux cas pour la segmentation d'images ultrasonores.

Dans ce chapitre, nous proposons, par analogie avec le système de vision humaine, une méthode de segmentation basée sur la logique floue et les approches multi échelles. Cette méthode vise à séparer une image en milieux, texturés ou non, et en zones de transition (zones de séparation entre deux milieux, cf. définition section 3.3.2). Cette première segmentation (grossière) permet l'étude de chacun des milieux composant l'image ainsi que des diverses zones de transition. Une quantification de la complexité des diverses régions ainsi extraites est effectuée via le calcul de la dimension fractale. Cet indice renseigne l'expert sur la complexité et la nature des objets présents dans l'image.

### **3.2 Approches floue et fractale de la perception humaine**

L'analyse des images, telles que les images ultrasonores, est difficile. On qualifie souvent ces images de complexes. Nous pouvons en effet différencier deux types de complexité : la complexité « structurelle » de l'image (arrangement des divers éléments la constituant), dépendante du bruit présent dans l'image initiale et de l'échelle d'observation choisie ; et la complexité d'analyse liée à l'interprétation humaine d'un phénomène. De nombreuses études psychovisuelles faisant intervenir une population d'experts, telles que

### 3.2 Approches floue et fractale de la perception humaine

l'étude ROC proposée, par exemple, par Delgorge [Delgorge, 2005] pour classifier divers résultats de compression, ont montré les différences qu'il pouvait y avoir entre deux médecins quant à l'interprétation d'une même image ultrasonore. Cette non unicité de diagnostic renforce l'idée d'une complexité d'analyse du phénomène (comme par exemple l'image ultrasonore). Le phénomène a pourtant une complexité particulière dont la caractérisation pourrait aiguiller l'expert dans sa démarche d'analyse et d'aide à la décision du diagnostic.

En réponse au problème soulevé par cette double complexité (structurelle et d'analyse), nous proposons dans un premier temps une méthode d'analyse par logique floue. Cette approche consiste en une segmentation grossière de l'image traitée en objets tout en s'accommodant du bruit présent dans l'image et de l'échelle d'observation. Viendra ensuite une quantification de la complexité des éléments extraits. Cette étape sera rendue possible par le calcul de leur dimension fractale.

#### 3.2.1 Spécificité de la vision humaine

Fin des années 70, Marr est le premier à proposer des méthodes en vision par ordinateur inspirées de la vision humaine [Marr, 1976] [Marr et Nishihara, 1978]. La compréhension du système visuel humain facilite l'élaboration d'algorithmes performants et, réciproquement, sa modélisation améliore la compréhension du phénomène biologique.

Dans ses travaux, Marr définit clairement les étapes successives constituant la vision par ordinateur [Marr, 1982]. Appelée approche « ascendante », la méthode débute par l'extraction de caractéristiques, de primitives de base, définies localement en chaque pixel de l'image. Il aboutit alors à l'interprétation plus globale de l'image faisant intervenir une interaction entre les divers éléments des couches inférieures de l'algorithme (primitives de base).

De façon similaire aux peintures pointillistes dans lesquelles chaque tache indépendante se fond dans un ensemble (en une texture homogène, au fur et à mesure que l'on s'éloigne de la toile), une image numérique peut être vue comme un ensemble de pixels indépendants interagissant les uns avec les autres. Ce phénomène est bien évidemment dépendant de l'échelle d'observation correspondant à la distance entre l'observateur et l'objet visionné. La Figure 1 est un exemple d'image de taille finie perçue à différentes échelles d'observation

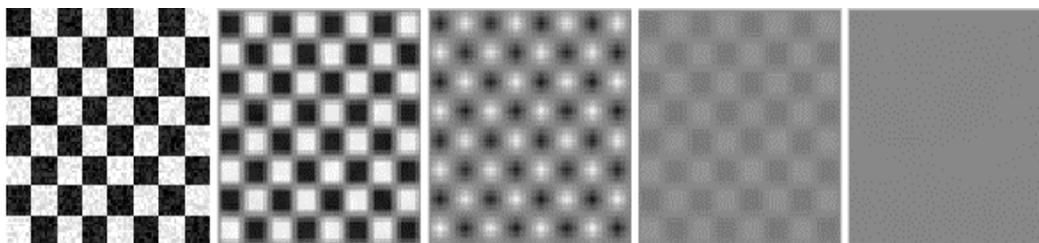


Figure 1 : Affichage d'une image vue à divers niveaux d'observation (texture avec pixels de couleur blancs et noirs qui s'homogénéisent)

Ainsi, la perception que l'on a de l'objet est dépendante de la distance qui nous en sépare. Bien évidemment, la taille du voisinage avec lequel chaque élément de base va interagir dépendra de l'échelle d'observation. On peut alors distinguer les éléments faisant partie intégrante d'un ensemble (d'un milieu), des éléments pour lesquels la classification devient ambiguë et délicate. Si la notion de différentes échelles d'observation fait référence aux objets fractals, cette spécificité d'un pixel à appartenir ou non, de façon nette ou imprécise, à un ensemble, correspond aux notions de base de la logique floue. Nous précisons ici rapidement ce concept.

### **3.2.2 Introduction à la logique floue**

Formalisée par Zadeh en 1965, à partir du concept d'incertitude émergeant aux États Unis dans les années 1940, la logique floue permet de pallier les limites liées aux incertitudes laissées par les modèles mathématiques trop cartésiens du moment. Les premières applications apparaissent dans les années 1975 en Europe (avec notamment la modélisation du processus de régulation d'une chaudière par Mamdani) avant de connaître son plein essor au Japon au milieu des années 1980.

La logique floue va alors se retrouver dans bon nombre de produits industriels grand public tels que les appareils électroménagers, les appareils photo, dans certaines options automobiles (climatisation, ABS) et dans les transports (métro de Sendai en 1987 par exemple).

Cette technologie reste très présente de nos jours comme par exemple dans les domaines émergents tels que : le diagnostic médical, le diagnostic automobile, la robotique, dans la sécurité routière (gestion des feux rouges), la météorologie, les assurances et le domaine aérien (loi de commande d'un hélicoptère par Sugeno)

Cette approche offre une alternative à la logique booléenne, dite du tout ou rien. Elle utilise des états intermédiaires permettant de modéliser l'incertitude d'appartenance. Les sous-ensembles flous ont été introduits pour éviter les passages brusques d'une classe à une autre (Figure 2). Ils permettent ainsi à un élément de ne pas appartenir complètement à l'une ou l'autre classe (on

### 3.2 Approches floue et fractale de la perception humaine

pourrait ainsi faire l'analogie avec les 256 niveaux de gris intermédiaires d'une image en noir et blanc).

Il est aisé de faire le rapprochement avec la linguistique française très riche en termes imprécis. En effet, l'homme n'applique pas, au contraire des machines dont il est l'inventeur, de logique booléenne (oui/non) dans ses choix de tous les jours. Les expressions :

- « *il est presque grand* »,
- « *on est proche du but* »,
- « *vraiment très petit* »,
- « *environ* », « *à peu près* »

sont très difficiles à modéliser dans une logique booléenne (dite du « tout ou rien ») mais modélisables au sens de la logique floue.

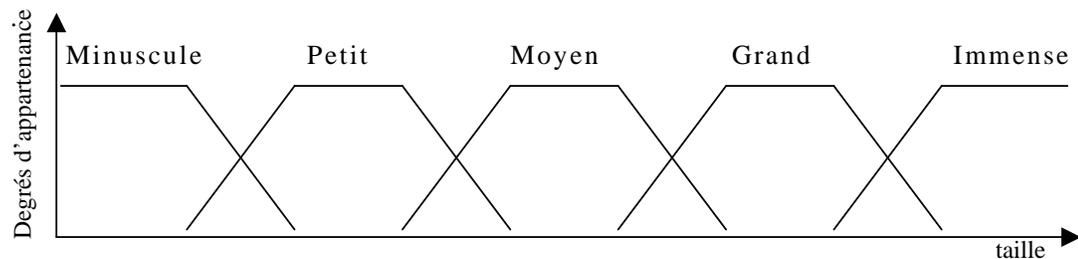


Figure 2 : Exemple de modélisation, par la logique floue, du concept de « taille » des *individus*

A l'aide de cette approche, qui permet de conserver un certain degré d'incertitude, on va ainsi pouvoir exprimer, pour une échelle d'observation donnée, un degré d'appartenance d'un pixel aux divers milieux constituant l'image. Le problème posé par la vision humaine du degré d'interaction d'un pixel avec son environnement sera traité par ce biais.

Dans la partie suivante, nous traitons de la complexité d'analyse ; qui apparaît dans les interprétations différentes d'un même phénomène par divers experts.

#### 3.2.3 Incertitude des « experts » face à un phénomène complexe

Les travaux visant à évaluer les résultats de segmentation, ont abouti à diverses méthodes, montrant la difficulté d'apporter une solution robuste et universelle. En effet, si l'on demande à un ensemble d'experts d'analyser une image quelconque, on s'aperçoit rapidement de la divergence des perceptions du phénomène. C'est à ce problème que se confrontent les nombreuses approches psychovisuelles plaçant l'expert au centre de l'évaluation.

N'ayant d'autres moyens actuellement que de se baser sur ses seuls acquis (formations et expériences d'actes d'échographie), l'expert, à partir de sa propre perception, interprète le phénomène sans pouvoir le vérifier concrètement. C'est cette imprécision dans l'analyse du phénomène qui nous oriente encore une fois vers l'utilisation de la logique floue. Cette approche

semble être en adéquation avec la difficulté d'interprétation et l'imprécision dans l'explication du diagnostic proposé par les médecins.

Une fois l'incertitude de la perception humaine du phénomène prise en compte, reste à traiter la complexité structurelle de l'image elle-même. Nous allons alors chercher à caractériser les divers éléments la constituant. Pour cela, nous nous sommes orienté vers une analyse fractale, cette approche étant fréquemment utilisée pour quantifier la complexité d'objets.

### 3.2.4 Introduction aux fractales

La théorie fractale, attribuée à Mandelbrot [Mandelbrot, 1982], a pour objectif de construire ou de décrire des objets de géométries diverses dont la complexité peut être très grande et qui échappaient aux outils utilisés jusqu'alors. La dimension fractale permet de mesurer la complexité, un degré d'irrégularité, des objets ou des phénomènes étudiés.

#### 3.2.4.1 Qu'est-ce qu'une fractale ?

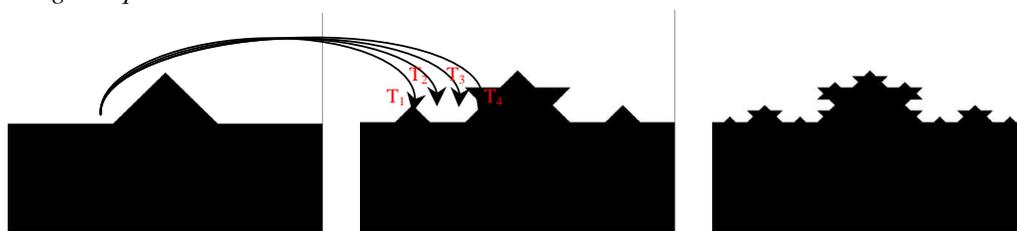
Le terme « fractale » est utilisé pour les courbes ou surfaces irrégulières construites à partir de processus déterministes ou stochastiques.

Dans la pratique, on peut par exemple construire une image fractale en partant d'un objet graphique auquel on applique une certaine transformation qui ajoute un élément de complexité, puis en appliquant la même transformation au nouvel objet ainsi obtenu ; ce qui accroît encore sa complexité ; on recommence ce processus itératif à l'infini (Figure 3 et Figure 4).

Nous présentons ici deux exemples qui seront utilisés par la suite pour illustrer notre méthode. Les courbes ont été mises en évidence par les 2 domaines qu'elles séparent, l'un indiqué en blanc et l'autre en noir.

*Exemple 1:*

*A partir d'un segment original de longueur «  $3n$  », on découpe ce segment en trois segments plus petits de même taille «  $n$  » et on remplace le segment central par deux autres segments qui, avec le segment retiré, forment un triangle équilatéral.*



*Figure 3 : Les 3 premières itérations de la construction d'une des courbes de Von Koch. Chaque segment est ainsi décomposé à l'itération suivante en 4 autres segments (issus de quatre transformations différentes  $T_1$ ,  $T_2$ ,  $T_3$  et  $T_4$ ). La courbe est définie par la transition entre le blanc et le noir.*

### 3.2 Approches floue et fractale de la perception humaine

*Exemple 2 :*

*A partir d'un segment original de longueur « 4n », on découpe ce segment en quatre segments plus petits de même longueur « n » et on construit la figure suivante composée de 8 segments de longueur « n ».*



*Figure 4 : Les 3 premières itérations pour une courbe de Minkowski. La courbe est définie par la transition entre le blanc et le noir.*

L'ensemble des transformées, correspondant à l'application récursive d'une ou plusieurs transformations contractantes (application  $k$ -lipschitzienne avec un paramètre  $k \in [0,1[$ ) d'un même espace métrique complet  $M$ , est appelé IFS (systèmes de fonctions itérées) [Fisher et al., 1992] [Hutchinson, 1981] [Barnsley, 1988] et constitue un modèle de la fractale.

Soit  $T_i$  une de ces transformations :

$$T_i : M \rightarrow M$$

Alors l'IFS correspondant à l'application de ces transformations se traduit par :

$$T = \bigcup_i T_i : M \rightarrow M$$

L'objet résultant de l'itération à l'infini du processus est appelé « attracteur » :

$$\lim_{n \rightarrow \infty} T^n(F_0) = Att$$

avec  $F_0$  un compact non vide.

En effet, quel que soit le support initial, l'attracteur final reste identique. Cette propriété découle directement du théorème du point fixe suivant :

#### Théorème du point fixe

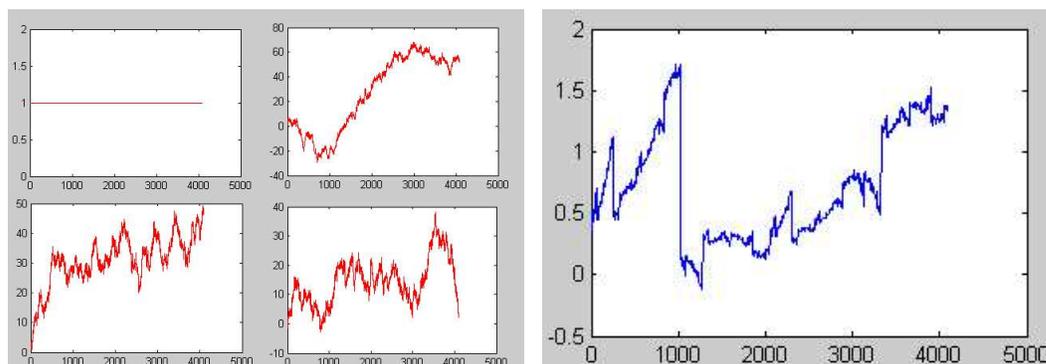
Soient un espace métrique complet  $M$  et une transformation contractante  $T$  de  $M$  dans lui-même. Il existe alors un unique point fixe «  $s$  » de  $T$  dans  $M$  ; il vérifie  $T(s)=s$ .

La génération de l'attracteur est donc indépendante de l'image en entrée, seuls comptent les paramètres des transformations contractantes pour la reproductibilité de l'objet.

Par exemple, nous pouvons nous attarder sur la Figure 5. Elle illustre un exemple d'IFS composé de 4 transformations mathématiques contractantes T1, T2, T3 et T4 définies de la façon suivante (x et y : coordonnées cartésiennes) :

$$\begin{array}{ll}
 T1 \left\{ \begin{array}{l} [0,4096] \times \mathfrak{R} \rightarrow [0,1024] \times \mathfrak{R} \\ (x, y) \rightarrow \left( \frac{x}{4}; 0,4 \times x + 0,2 \times y + 0,95 \right) \end{array} \right. & T2 \left\{ \begin{array}{l} [0,4095] \times \mathfrak{R} \rightarrow [1024,2048] \times \mathfrak{R} \\ (x, y) \rightarrow \left( \frac{x}{4} + \frac{1}{4}; 0,4 \times x + 0,2 \times y + 0,95 \right) \end{array} \right. \\
 T3 \left\{ \begin{array}{l} [0,4095] \times \mathfrak{R} \rightarrow [2048,3072] \times \mathfrak{R} \\ (x, y) \rightarrow \left( \frac{x}{4} + \frac{1}{2}; 0,4 \times x + 0,2 \times y + 0,95 \right) \end{array} \right. & T4 \left\{ \begin{array}{l} [0,4095] \times \mathfrak{R} \rightarrow [3072,4096] \times \mathfrak{R} \\ (x, y) \rightarrow \left( \frac{x}{4} + \frac{3}{4}; 0,4 \times x + 0,2 \times y + 0,95 \right) \end{array} \right.
 \end{array}$$

Nous avons appliqué cet IFS sur un ensemble de signaux en entrée tels que ceux représentés à gauche de la Figure 5. Quel que soit le support initial, signal simple ou signal aléatoire (brownien), la courbe de sortie reste toujours la même ; c'est l'attracteur de l'IFS.



*Figure 5 : Indépendance de l'attracteur de l'IFS vis-à-vis du support initial.  
A gauche, 4 courbes initiales différentes.*

*A droite, l'attracteur unique résultant de l'application de l'IFS sur ces supports.*

Prenons comme autre exemple le cas de la Figure 3. Un IFS correspond alors à l'union des quatre transformations  $T_i$  indiquées. On a sur cet exemple :

$$\forall (x, x') \in M^2, \quad \forall i \in [1,4], \quad |T_i(x') - T_i(x)| \leq \frac{1}{3} * |x' - x|$$

Toutes les transformations étant k-lipschitziennes avec  $k=1/3$ , l'IFS global est contractant. Selon le théorème du point fixe, cet IFS admet un unique attracteur : la courbe de Von Koch dans notre cas.

### 3.2.4.2 Propriétés des fractales

➤ L'autosimilarité ou invariance d'échelle : quel que soit le grossissement sur une figure donnée, on observera la même structure. Ce phénomène est lié à la construction même des fractales. En effet (Figure 6), une fractale peut être obtenue en appliquant, à chaque itération, la même transformation... ceci implique des similitudes entre les différents niveaux de construction de la figure.

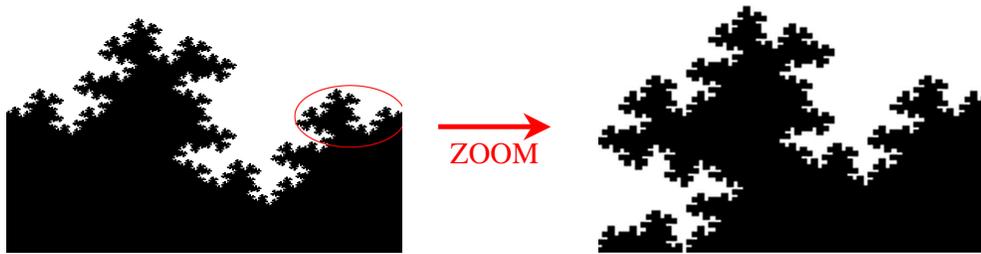


Figure 6 : Mise en évidence de l'invariance d'échelle sur la courbe de Minkowski. Un zoom au niveau de l'interface nous ramène sur une structure similaire à la forme originale.

Il existe aussi de très nombreux exemples de fractales dans la nature. On peut citer le chou fleur, les poumons humains, ou encore un coquillage (le *Cymbolia innexa* REEVE) dont l'enveloppe extérieure est tapissée de motifs ressemblant au triangle de Sierpinski (Figure 7). Ces éléments présentent une invariance d'échelle.

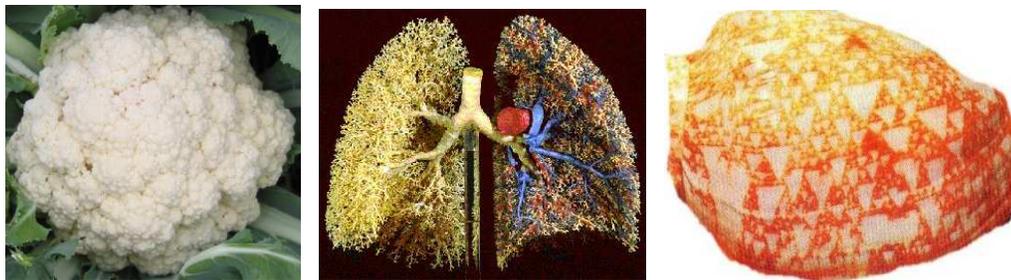


Figure 7 : Quelques exemples de fractales naturelles : le chou fleur, les poumons humains et le coquillage de Sierpinski (*Cymbolia innexa* REEVE).

Notons tout de même qu'il existe deux formes d'autosimilarité : l'autosimilarité déterministe, liée à la répétition d'un objet à différentes échelles, et l'autosimilarité statistique, liée au fait que pour toute échelle d'observation l'objet a statistiquement le même aspect.

➤ Curiosité Aire/Longueur : prenons l'exemple du flocon de Von Koch qui, à chaque itération, voit sa longueur multipliée par  $4/3$ . La longueur de son périmètre tend alors vers l'infini tout en conservant une aire finie inférieure à celle du disque circonscrit au triangle initial (Figure 8).

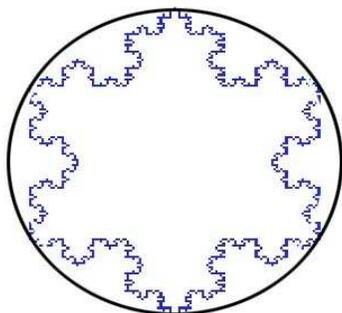


Figure 8 : Le flocon de Von Koch

Exemple :

La dimension de chacune des faces du triangle est la dimension de la courbe de Von Koch seule soit  $\text{Log}(4)/\text{Log}(3)$ .

(Dimension = 1,26)

C'est cette observation qui est à l'origine de la pensée fractale. C'est en voulant calculer la longueur de la côte Bretonne que Mandelbrot s'aperçut que plus il descendait en précision et plus la longueur du littoral augmentait. Ce phénomène s'explique facilement par l'invariance d'échelle se traduisant par une irrégularité inchangée de la côte et ce, quelle que soit l'échelle d'observation à laquelle on se situe.

➤ Leur Dimension (D) : presque tous les objets fractals ont des dimensions non entières. Cette dimension peut être calculée de différentes façons. Pour une fractale construite en itérant une transformation contractante, telle que celles présentées au paragraphe précédent, une approximation de cet indice peut être obtenue en utilisant la dimension d'autosimilarité définie par :

$$D = \frac{\log(\text{nombre de segments})}{\log(\text{rapport d'un nouveau segment / à l'initial})^{-1}}$$

Quel que soit l'objet pour lequel on désire estimer cette propriété, sa dimension fractale restera strictement positive ou nulle et ne pourra dépasser la dimension de l'espace de plus petite dimension topologique l'incluant entièrement. Ainsi, pour une figure comprise dans un plan, la dimension fractale d'un tel objet ne pourra pas excéder la valeur 2 (la dimension topologique des surfaces).

### 3.2.4.3 Domaines d'application des fractales

Aujourd'hui très développée, cette approche est présente dans de nombreux domaines. On la retrouve pour la modélisation de signaux : interpolation [Barnsley, 1986] [Mazel et Hayes, 1992], la parole [Lévy-Véhel et al., 1994], les électrocardiogrammes et électroencéphalogrammes [Oien et Narstad, 1995] [Mitra et Sarbadhikari, 1997], dans la synthèse d'objets : paysage, arbres [Jones, 2001], et même dans des œuvres artistiques (expositions d'images fractales).

### 3.2 Approches floue et fractale de la perception humaine

Le plus grand champ d'application reste actuellement celui de la compression de données (2D comme 3D). S'appuyant sur les IFS, on cherche à déterminer un ensemble de transformations contractantes dont le point fixe, l'attracteur, se rapproche le plus possible de l'objet initial (l'image, le volume...) à compresser [Fisher, 1995a] [Lu et Yew, 1994]. De nombreux travaux existent dans le domaine à commencer par ceux de [Barnsley et Jacquin, 1988] ; plutôt que de s'intéresser à l'image entière, ils proposèrent de partitionner l'image à compresser en imagerie plus petites : « les ranges blocs » et de rechercher les transformations permettant de retrouver ces ranges blocs à partir de zones plus importantes de l'image initiale. Chaque range bloc peut ainsi être codé sous la forme d'une transformation mathématique [Fisher, 1994] (fonctions de réajustement : rotation, changement d'échelle ; fonctions d'intensité : ajout de luminance, de contraste) calculés à partir d'autres régions de l'image originale (« domaines blocs »).

Depuis, de nombreuses recherches ont été menées dans le but d'améliorer la qualité de l'image décompressée et le temps nécessaire à la recherche des transformations (ce qui correspond au fichier compressé). On peut citer de manière non exhaustive les travaux (images en niveaux de gris) sur des partitionnements différents de l'image à compresser (à l'aide d'une triangulation de Delaunay [Davoine, 1995], en quadtree [Fisher, 1995b], avec superposition des ranges blocs possibles [Reusens, 1994]) ; sur l'optimisation de la recherche des domaines blocs adéquats (recherche cyclique) [Barthel et Voye, 1994], aléatoire [Ghosh et al., 2004], en étudiant la variance intra bloc [Chen et al., 2002], voire même via l'utilisation d'un algorithme génétique [Mitra et al., 1998]) et d'autres extensions (algorithmes hybrides [Truong et al., 2000] [Li et Kuo, 1999], la transposition aux images couleur [Hürtgen et al., 1994]).

#### 3.2.5 Présentation de la méthode envisagée

Afin de traiter au mieux les images ultrasonores, et particulièrement cette double complexité structurelle/analyse, nous découperons notre approche en deux parties :

- Tout d'abord la recherche des transitions séparant les divers milieux présents dans l'image. Pour cela, une approche par logique floue, permettant de prendre en considération le fonctionnement de la vision humaine, est développée dans la section 3.3. Elle doit permettre d'extraire, non pas l'interface réelle, nécessitant l'obtention précise d'une segmentation de l'image, mais une transition grossière (englobant l'interface). Nous reviendrons plus en détail sur les notions d'interface et de transition à la section 3.3.2.
- Ensuite la caractérisation des divers composants de l'image (milieux et interfaces). Une approche par calcul de dimension fractale, présentée en 3.4, va nous permettre de quantifier leur complexité. Nous serons alors

en mesure de proposer au médecin une aide à l'interprétation de la « scène » par une mesure quantitative de la complexité de ses éléments.

### **3.3 L'approche floue**

Pour simplifier la présentation, nous nous plaçons dans le cadre de l'étude d'une image synthétisée, présentant deux milieux, un clair et un sombre, séparés par une surface de contact que nous nommerons par la suite transition. Afin de déterminer cette zone, nous allons quantifier, via une approche floue, le degré d'appartenance d'un pixel aux deux milieux dits de référence. Ils correspondent aux milieux entre lesquels nous cherchons à quantifier l'interface (les milieux noir et blanc dans cette section). De cette notion de degré d'appartenance d'un pixel à un milieu découlera, par la suite, la notion plus globale de coefficient de pureté.

#### **3.3.1 Concepts, définitions**

Avant de voir comment sont déterminés les degrés d'appartenance, dont découle le coefficient de pureté, il est nécessaire de passer par une notion transitoire qui est celle de point intérieur à un milieu.

##### **3.3.1.1 Notion de pixel intérieur à un milieu**

**Définition** : Un pixel est intérieur à un milieu si tous ses voisins appartiennent, eux aussi, au même milieu (points  $P_1$  et  $P_3$  de la Figure 9).

Remarque :

Le voisinage peut prendre différentes formes. Il peut s'agir d'un voisinage en 4 ou 8-connexité dans le cas le plus simple mais d'autres choix peuvent être faits (voisinage isotrope, anisotrope, disque, rectangle, carré).

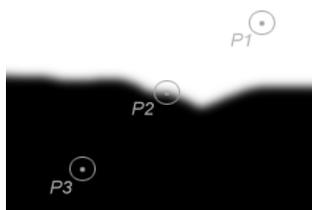


Figure 9 : Notion de points intérieurs ( $P_1$  et  $P_3$ )

Sur la Figure 9, les points  $P_1$  et  $P_3$  sont intérieurs respectivement aux milieux blanc et noir. En effet, pour un rayon de voisinage spécifié, tous leurs voisins appartiennent eux aussi au milieu les incluant. *A contrario*, les pixels appartenant au voisinage du point  $P_2$ , ne sont pas tous dans le même milieu que  $P_2$ .  $P_2$  n'est donc pas un point intérieur à l'un des deux milieux de référence. Les concepts de « pixel intérieur » et « d'échelle d'observation » sont évidemment liés. Un pixel est donc intérieur à un milieu pour une représentation et un rayon de voisinage ( $R$ ) donnés. En effet, pour un voisinage de forme carrée, de côté  $2R+1$ , nous n'aurons pas le même ensemble

### 3.3 L'approche floue

de pixels « voisins » que pour un voisinage représenté sous forme d'un disque de rayon R.

#### 3.3.1.2 Notion de degré d'appartenance à un milieu

Soit  $F_p$  une fonction croissante, définie sur l'intervalle  $[0, R]$ . Nous ne considérons que les familles de fonctions majorées par la fonction  $F$  obtenue dans le cas d'un point intérieur à l'un des deux milieux de référence. Évidemment, ces propriétés sont vérifiées par de nombreuses fonctions  $F_p$  qui dépendent du contenu du voisinage de P considéré. Le milieu correspondant à la borne supérieure est le milieu de référence que nous noterons milieu 1.

Prenons, par exemple pour un pixel P, le cas de la fonction définie par la somme des niveaux de gris des pixels du voisinage de P de rayon r (r variant de 1 à l'échelle d'observation R). La Figure 10 représente l'évolution des fonctions  $F_{P1}$ ,  $F_{P2}$  et  $F_{P3}$  associées aux points P1, P2 et P3 de la Figure 9, donc pour des points intérieurs aux deux milieux de référence et un point appartenant à leur zone de transition. C'est cette fonction qui est utilisée dans toutes les illustrations que nous proposons par la suite.

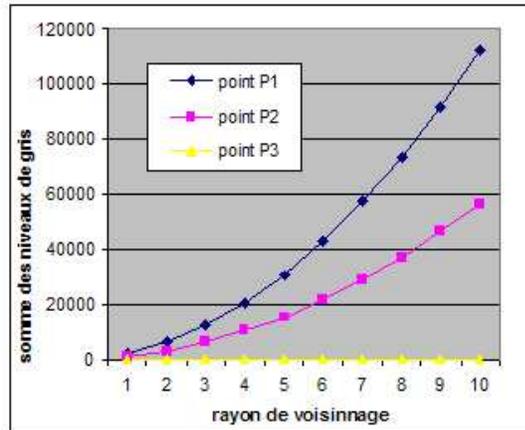


Figure 10 : Évolution de la fonction  $F_p$  pour les points P1, P2 et P3 de la Figure 9 pour  $R=10$ .  $F$  est ici égale à  $F_{p1}$

**Définition :** Le degré d'appartenance du pixel P au milieu de référence, à une échelle d'observation R donnée, est alors défini comme le rapport entre les aires limitées d'une part par les courbes associées respectivement à  $F_p$  et  $F$  et d'autre part l'axe des abscisses :

$$m_1(P, R) = \frac{\int_0^R F_p(r) dr}{\int_0^R F_{p1}(r) dr} = \frac{\int_0^R F_p(r) dr}{\int_0^R F(r) dr}$$

On note  $m_1(P, R)$  le degré d'appartenance du pixel P au milieu de référence, ici le plus clair (milieu 1). Nous adoptons cette convention dans la suite de la présentation.

Dans ce cas, on en déduit  $m_2(P,R)$ , le degré d'appartenance de P à l'autre milieu :

$$m_2(P,R) = 1 - m_1(P,R)$$

La deuxième relation impose le fait que  $m_1(P,R) + m_2(P,R) = 1$  ; donc le fait que nous soyons uniquement en présence de 2 milieux.

Ces définitions intègrent implicitement une modélisation de la vision humaine. Dans le cas le plus simple,  $R=0$  et les pixels apparaissent indépendants les uns des autres. Les degrés d'appartenance sont alors réduits au rapport des niveaux de gris ( $F_p(0)/F(0)$ ).

Remarque :

Les images traitées étant numériques, nous nous trouvons en réalité dans un domaine discret et non un domaine continu. En effet, la différence de niveau de gris entre deux pixels voisins pouvant être significative, nous ne pouvons employer, pour des problèmes de continuité, les intégrales dans le calcul des degrés d'appartenance [Chassery et Montonvert, 1991]. Elles sont alors remplacées par des sommes.

<u>Domaine continu :</u>	<u>Domaine discret :</u>
$m_1(P,R) = \frac{\int_0^R F_p(r) dr}{\int_0^R F(r) dr}$	$m_1(P,R) = \frac{\sum_{r=0}^R F_p(r)}{\sum_{r=0}^R F(r)} \quad (1)$

### 3.3.1.3 Perception à différentes échelles d'observation

Comme proposé au point 3.2.1, la perception humaine est dépendante de l'échelle d'observation à laquelle on se place pour regarder l'objet. Les degrés d'appartenance calculés à la section précédente permettent de modéliser cet aspect. En effet, selon la valeur de R choisie, les degrés d'appartenance sont calculés selon des rayons de voisinage différents. Plus R est élevé, plus le nombre de pixels avec lesquels le pixel étudié interagit est important.

Ainsi, les degrés d'appartenance des pixels au milieu le plus clair peuvent être perçus comme les niveaux de gris, normalisés dans l'intervalle [0,1], des pixels de l'image observée à l'échelle R. La Figure 12 est un exemple d'image (Figure 11) perçue à différentes échelles d'observation.

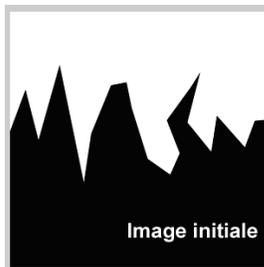


Figure 11 : Image initiale vue à une échelle d'observation  $R=0$

### 3.3 L'approche floue

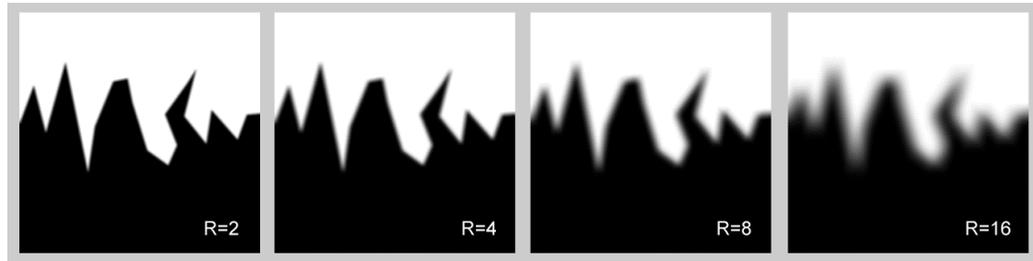


Figure 12 : Perception à différentes échelles d'observation ( $R = 2, 4, 8$  puis  $16$ ). Chaque pixel de l'image interagit ainsi avec les pixels voisins (carré de côté  $2R+1$  pixels centré sur le pixel étudié).

#### 3.3.1.4 Notion de coefficient de pureté

**Définition** : Le coefficient de pureté d'un pixel  $P$  à l'échelle d'observation  $R$  est donné par la relation :

$$c(P, R) = \max\{ m_1(P, R) ; m_2(P, R) \}$$

Cet indice appartient à l'intervalle  $[\frac{1}{2} ; 1]$ . Il prend la valeur 1 pour un pixel intérieur à l'un des deux milieux et la valeur  $\frac{1}{2}$  lorsque le maximum d'indécision est atteint. Un pixel est donc dit « pur » lorsqu'il appartient totalement à l'un des milieux ( $m_1(P, R)=1$  ou  $m_2(P, R)=1$ ). En d'autres termes, ce pixel est intérieur à un milieu quelle que soit l'échelle d'observation  $r$  appartenant à l'intervalle  $[0 ; R]$ .

**Remarque** :

La valeur  $\frac{1}{2}$  correspond au cas où  $m_1(P, R)=m_2(P, R)$ . Le pixel  $P$  appartient alors autant à l'un qu'à l'autre des deux milieux. Dans le cas d'une image appartenant au domaine continu, la valeur  $\frac{1}{2}$  est généralement atteinte pour l'utilisation d'un voisinage isotrope. Par contre, les images numériques appartenant par construction au domaine discret (avec le pixel comme unité spatiale), ne vérifient pas forcément cette observation (Figure 13).

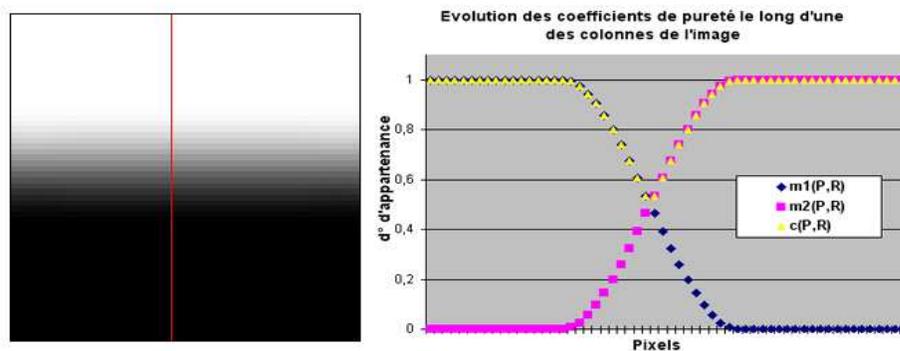


Figure 13 : Image et représentation des coefficients de pureté des pixels appartenant à la colonne spécifiée de l'image. Le minimum des  $c(P, R)$  de la colonne est de 0,53.

La Figure 13 met bien en évidence le lien monotone entre le coefficient de pureté  $c(P,R)$  et la distance à l'interface naturelle entre les 2 milieux. Nous étudierons à la section 3.3.3, le cas d'une configuration d'interface à courbure finie et constante telle que représentée Figure 14 où nous nous intéresserons à la zone du demi disque.

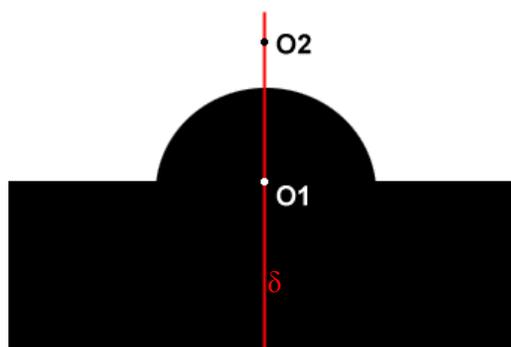


Figure 14 : Interface à courbure constante et finie entre deux milieux. La droite  $\delta$  est définie comme la droite passant par le centre  $O_1$  du demi disque et par  $O_2$ , chacun dans un des deux milieux.

### 3.3.2 Approche théorique

Avant de s'intéresser aux images ultrasonores et dans l'optique de faciliter la compréhension de l'algorithme, notre étude va se limiter dans un premier temps aux images de synthèse connues. En modifiant l'échelle des niveaux de gris (dans l'intervalle  $[0, 1]$  par exemple), chaque valeur peut être interprétée comme le degré d'appartenance du pixel au milieu le plus clair (niveau de gris à 1 ici). Rappelons que l'objectif de cette section est de caractériser la transition entre ces deux milieux sans extraire de manière explicite l'interface entre les 2 milieux, c'est-à-dire en évitant une étape de segmentation.

Notons que dans le reste du manuscrit nous distinguerons les termes transitions et interfaces. Nous définissons ici la signification donnée:

- **Une transition** entre deux milieux correspond à une zone frontière entre ces milieux regroupant les pixels pour lesquels la classification dans l'un ou l'autre des milieux devient difficile. L'épaisseur de la transition est fortement liée à l'échelle d'observation  $R$  choisie initialement. La zone ainsi délimitée englobe l'interface entre les deux milieux.
- **L'interface** entre deux milieux correspond à la courbe délimitant au mieux les deux milieux. C'est une transition dont l'épaisseur deviendrait nulle. Elle se traduit par un ensemble de pixels de 1 pixel d'épaisseur.

#### 3.3.2.1 Extraction des transitions

Par définition, les pixels appartenant à la transition entre les deux milieux, sont ceux pour lesquels l'indécision pour la classification, vis-à-vis des deux

### 3.3 L'approche floue

milieux de référence symbolisés ici par un niveau de gris, est maximale. Leurs coefficients de pureté sont alors minimaux. Le minimum sur l'image est supérieur ou égal à  $\frac{1}{2}$  (qui n'est pas forcément atteint). Ainsi, seuls les pixels ayant les plus faibles coefficients de pureté sont considérés.

Plus précisément,  $M^R$  est défini comme le minimum des coefficients de pureté des pixels de l'image à l'échelle d'observation R donnée :

$$M^R = \min_{P \in \text{Image}} \{ c(P, R) \}$$

Le choix de cette définition est lié en particulier au caractère discret du domaine d'application. Comme déjà cité précédemment, le minimum des coefficients de pureté pour une image comprenant deux milieux bien contrastés et appartenant au domaine continu, serait de  $\frac{1}{2}$ , ce qui n'est pas systématiquement le cas pour une image numérique. Les points qui nous intéressent ne sont pas nécessairement des minimums globaux de  $\frac{1}{2}$  mais sont des minimums globaux dont les valeurs sont proches de  $\frac{1}{2}$  et très peu différentes les unes des autres (différentes mais d'écart faible). Considérer dans une zone de transition uniquement les pixels de coefficient de pureté  $c(P, R)$  égal au minimum global  $M^R$  serait trop restrictif ; on pourrait alors penser à prendre en compte les minimums locaux ; ceci conduit à une trop grande discontinuité des zones obtenues. Nous proposons donc une définition moins restrictive pour caractériser la zone de transition.

**Définition** : Une zone de transition est définie comme l'ensemble des pixels ayant leur coefficient de pureté compris dans l'intervalle :

$$[ M^R , \min (M^R + k, 1) ] \text{ où } k \text{ est un réel.}$$

Le paramètre  $k$ , dit de sensibilité, peut être soit fixé par l'utilisateur (valeur très faible de l'ordre de 0,03) soit calculé directement à partir des coefficients de pureté (2% de la différence «  $1 - M^R$  » par exemple). Le coefficient de pureté étant inférieur ou égal à 1, la borne supérieure de l'intervalle peut être majorée par 1. De plus, on peut remarquer ici que les points dont le coefficient de pureté est égal à 1 appartiennent sans ambiguïté à un des milieux.

Les pixels ainsi sélectionnés définissent une zone appelée « zone de transition » (Figure 15 et Figure 16), incluant l'interface réelle (Figure 17). La taille de la transition est bien évidemment dépendante de l'échelle d'observation « R » mais aussi du choix du paramètre « k » (Figure 18).

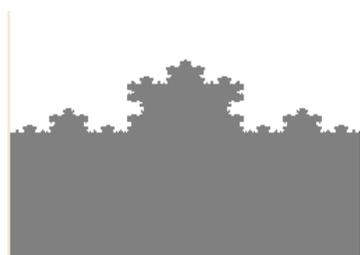


Figure 15 : Image synthétique où l'interface est une courbe de Von Koch séparant deux milieux uniformes.



Figure 16 : Transition (noire) obtenue pour une valeur de  $k=0,03$  et  $R=5$  à partir de la Figure 15.

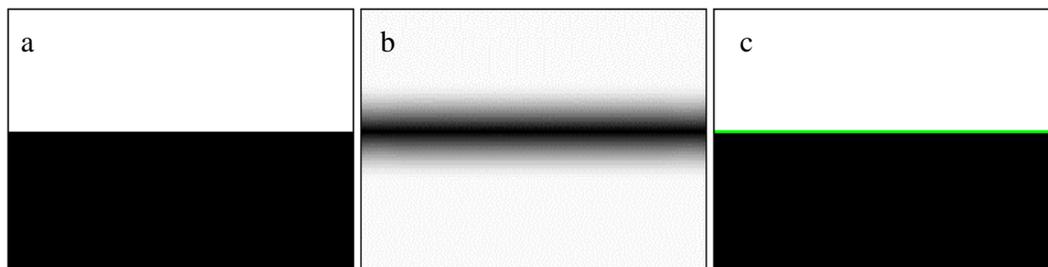


Figure 17 : Coefficients de pureté (b) obtenus pour  $R=32$  sur l'image (a) et recalés dans l'intervalle  $[0, 255]$ . La figure (c) représente l'image initiale sur laquelle est superposée la zone de transition obtenue ( $k=0,01$ ). Cette zone englobe l'interface réelle recherchée.



Figure 18 : Transitions obtenues sur l'image de la Figure 13 ( $R=10$ ).

A gauche : une transition extraite avec 0,03 en paramètre de sensibilité.  
A droite : transition regroupant les pixels n'appartenant pas totalement à l'un des deux milieux donc pour lesquels  $d(P,R) \in [M^R, 1[$

Contrairement aux techniques de segmentation habituelles, visant à positionner avec exactitude l'interface, cette méthode ne permet d'obtenir qu'une zone incluant cette interface. L'inconvénient de la méthode réside dans l'obtention d'une transition épaisse. Cette épaisseur, fonction du paramètre de sensibilité  $k$  ainsi que de la valeur affectée à  $R$ , ne permet pas de respecter la définition d'une interface. Nous voulons alors, tout en conservant les propriétés de la zone de transition, diminuer son épaisseur. Une étape de squelettisation nous paraît tout à fait appropriée.

### 3.3.2.2 Estimation de l'interface

Dans le but de caractériser l'interface réelle, nous nous proposons d'en rechercher une estimation dépendant de l'échelle d'observation. Nous nous

### 3.3 L'approche floue

basons bien évidemment sur la zone de transition précédemment obtenue. La structure ainsi extraite devra conserver les propriétés topologiques de la zone de transition (même nombre de composantes connexes, même allure générale) tout en ayant une épaisseur la plus faible possible.

Une approche intuitive, en réponse au problème d'approximation de l'interface à partir de la zone de transition, consiste en l'utilisation du squelette de la zone de transition précédemment obtenue comme représentation de la réelle interface (Figure 19).

Parmi les nombreuses méthodes existantes, la méthode de squelettisation retenue est choisie en fonction de sa faculté à conserver le nombre de composantes connexes de la structure (conservation du nombre d'Euler), c'est l'Axe Médian de BLUM [Blum, 1967]. Elle permet d'obtenir un ensemble d'épaisseur 1 et une bonne localisation du squelette [Dupont, 2003] au centre de la structure.

**Définition :** l'Axe Médian de BLUM est le squelette d'un ensemble  $X$  selon une famille de boules  $\{\delta_n\}$  ; c'est le lieu géométrique des centres de toutes les boules maximales au sens de l'inclusion.

La phase de squelettisation retenue, en plus de fournir une structure d'épaisseur faible (1 pixel d'épaisseur en 4-connexité), est une transformation homotopique présentant l'avantage de conserver les propriétés topologiques de la zone de transition. Aujourd'hui encore, cette méthode reste couramment utilisée [Dupont, 2003].



Figure 19 : Exemples de squelettes obtenus (par ordre d'apparition) sur des milieux séparés par la courbe de Minkowski (Figure 4), l'image de la Figure 13 et les milieux séparés par la courbe de Von Koch (Figure 16).

La complexité (l'irrégularité) de la courbe ainsi obtenue est logiquement liée au choix des deux paramètres que sont l'échelle d'observation «  $R$  » et le paramètre de sensibilité «  $k$  ». Une augmentation d'une de ces deux valeurs aura comme conséquence un lissage de la transition puis, par conséquent, de son squelette. L'incidence du choix des paramètres est détaillée dans la section suivante.

### 3.3.3 Influence des paramètres k et R

#### 3.3.3.1 Échelle d'observation et zone de transition

Le choix de l'échelle d'observation influe sur la dimension des transitions obtenues. Comme représenté sur la Figure 20, plus l'échelle d'observation (R) choisie est importante, plus la zone de séparation entre les deux milieux semble large et lissée. On assistera alors à une vue d'ensemble du phénomène, au détriment du détail.

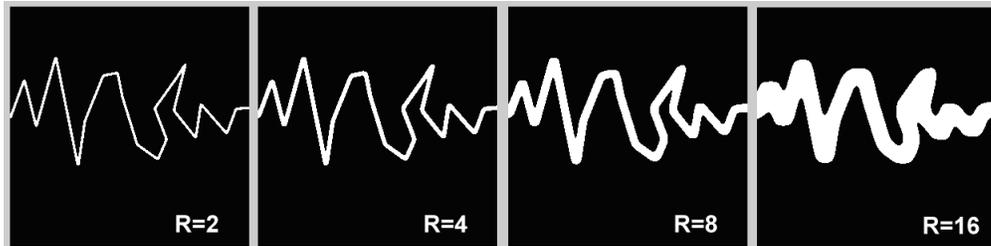


Figure 20 : Évolution de la zone de transition entre les milieux blanc et noir de la Figure 11 pour différentes valeurs d'échelle d'observation ( $R = 2, 4, 8$  puis  $16$  ;  $k = 1-M^R$ ) et sans utilisation du facteur de sensibilité  $k$ .

Pour conforter les idées intuitives que l'on peut avoir sur les rôles de  $k$  et de  $R$ , dans l'épaississement de la zone de transition, nous pouvons constater que cette conclusion est vérifiée sur l'image de la Figure 13. De manière plus rigoureuse, nous allons faire les calculs dans le cas d'une interface à courbure constante (Figure 14).

Pour cela, considérons la Figure 21. Nous cherchons à exprimer le degré d'appartenance du point  $O_2$  au milieu de référence représenté par le disque  $D_1(O_1, r_1)$  en fonction de  $R$ . Pour cela, nous devons considérer des disques centrés en  $O_2$  dont les rayons  $r_2$  varient. Nous nous limiterons aux cas  $r_1 \geq r_2$ . Le calcul est basé sur l'intersection des deux disques  $D_1(O_1, r_1)$  et  $D_2(O_2, r_2)$ .

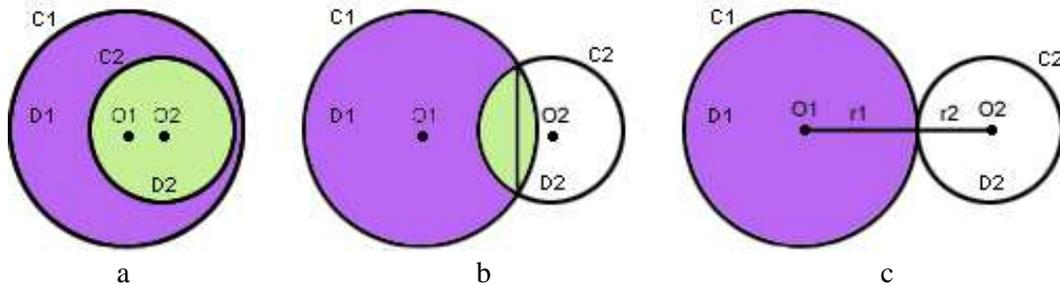


Figure 21 : Différentes configurations (a, b et c), à  $R$  donné, d'intersections (verte) entre le disque  $D_1(O_1, r_1)$  représentant un milieu de référence et un disque  $D_2(O_2, r_2)$  symbolisant le rayon du voisinage circulaire adopté pour le calcul des degrés d'appartenance. On considère comme milieux de référence, le disque violet défini par le cercle  $C_1(O_1, r_1)$ , et la zone extérieure au cercle (en blanc sur la figure).

### 3.3 L'approche floue

3 cas sont à distinguer en fonction de la distance  $d$  séparant les centres  $O_1$  et  $O_2$  des deux disques  $D_1(O_1, r_1)$  et  $D_2(O_2, r_2)$  :

- Cas  $d \geq r_1 + r_2$  ; le point  $O_2$  et l'ensemble des points appartenant à son voisinage sont extérieurs au disque  $D_1(O_1, r_1)$ . L'intersection entre les deux disques est alors nulle (Figure 21c).
- Cas  $d < |r_1 - r_2|$  ; l'intégralité du voisinage de  $O_2$  est alors contenu dans le disque  $D_1(O_1, r_1)$ . L'intersection entre les deux disques correspond alors à l'aire du disque  $D_2(O_2, r_2)$ , soit  $\pi * r_2^2$  (Figure 21a).
- Cas  $|r_1 - r_2| < d < r_1 + r_2$ , l'aire commune aux deux disques peut alors s'écrire (Figure 21b):

$$A = r_2^2 \operatorname{Arccos}\left(\frac{d^2 + r_2^2 - r_1^2}{2dr_2}\right) + r_1^2 \operatorname{Arccos}\left(\frac{d^2 + r_1^2 - r_2^2}{2dr_1}\right) - \frac{1}{2} \sqrt{4d^2 r_1^2 - (d^2 - r_2^2 + r_1^2)^2}$$

#### Démonstration :

Cherchons à mesurer l'aire définie par l'intersection de ces deux cercles. Pour cela, définissons les variables utilisées par la suite. Ces variables sont illustrées à la Figure 22.

Soient :

- $O_1$  et  $O_2$  les centres des deux cercles respectifs  $C_1$  et  $C_2$  de rayons respectifs  $r_1$  et  $r_2$ .
- $d$  la distance séparant  $O_1$  et  $O_2$ .
- $I_1$  et  $I_2$  les points d'intersection de ces deux cercles. Ils sont distant l'un de l'autre d'une valeur  $a$ .
- $\alpha_1$  et  $\alpha_2$ , les angles  $I_1 O_1 I_2$  et  $I_1 O_2 I_2$  respectivement.
- $h_1$  (resp.  $h_2$ ) la hauteur du triangle  $I_1 O_1 I_2$  (resp.  $I_1 O_2 I_2$ ) passant par  $O_1$  (resp.  $O_2$ ).

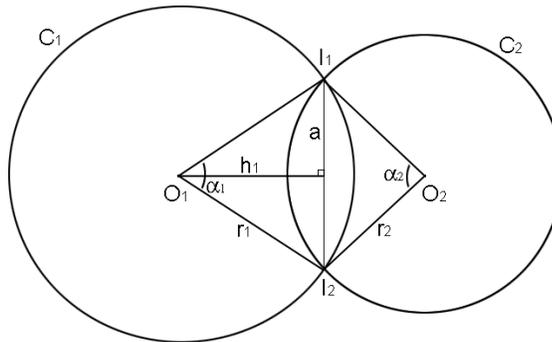


Figure 22 : Représentation de l'intersection entre deux cercles  $C_1(O_1, r_1)$  et  $C_2(O_2, r_2)$ .

Le calcul de l'aire de l'intersection est décomposé en deux portions limitées par  $I_1 I_2$ . Les aires de chaque portion peuvent être décomposées :

$$A = \text{aire}(\text{secteur}_{\text{circulaire}}) - \text{aire}(\text{triangle}_{\text{O}_1 \text{I}_1 \text{I}_2})$$

Appréhension quantitative et qualitative des objets

Prenons comme référentiel le centre du cercle  $C_1$  donc  $O_1(0,0)$ . Les équations respectives des deux cercles peuvent alors s'écrire :

$$x^2 + y^2 = r_1^2 \quad \text{et} \quad (x-d)^2 + y^2 = r_2^2$$

En combinant ces deux équations afin de retrouver les coordonnées des points d'intersection  $I_1$  et  $I_2$ , on obtient les relations :

$$x_{I_1} = x_{I_2} = \frac{d^2 - r_2^2 + r_1^2}{2d} \quad \text{et}$$

$$y_{I_1}^2 = y_{I_2}^2 = r_1^2 - x_{I_1}^2 = r_1^2 - \left( \frac{d^2 - r_2^2 + r_1^2}{2d} \right)^2 = \frac{4d^2 r_1^2 - (d^2 - r_2^2 + r_1^2)^2}{4d^2}$$

La distance  $a$  entre les points d'intersection étant égale à  $|2y|$  dans notre cas, nous pouvons l'exprimer elle aussi en fonction de  $d$ ,  $r_1$  et  $r_2$ .

$$a = \frac{1}{d} \sqrt{4d^2 r_1^2 - (d^2 - r_2^2 + r_1^2)^2}$$

La distance 'a' calculée, les aires des triangles  $O_1 I_1 I_2$  nous permettent le calcul des aires des secteurs circulaires de chacun des cercles définis par leurs centres et les angles  $\alpha_1$  et  $\alpha_2$  (Figure 23).

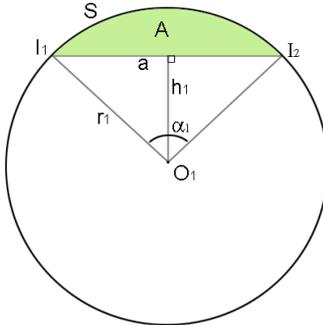


Figure 23 : Représentation de l'aire recherchée. L'aire de A s'obtient en soustrayant l'aire du triangle  $I_1 O_1 I_2$  du secteur circulaire définie par  $O_1(r_1, \alpha_1)$ .

Pour arriver à un tel résultat, nous devons exprimer la mesure de l'angle  $\alpha_1$ . S notant aussi bien l'arc que la mesure de l'arc, définie par sa longueur :

$$\alpha_1 = \frac{S}{r_1} = 2 * \text{Arccos} \left( \frac{h_1}{r_1} \right)$$

Puis exprimer l'aire du segment circulaire (A):

$$A = \text{aire}(\text{secteur\_circulaire}) - \text{aire}(\text{triangle\_} O_1 I_1 I_2)$$

$$A = \frac{1}{2} r_1^2 \alpha_1 - \frac{1}{2} r_1^2 \sin(\alpha_1)$$

$$A = \frac{1}{2} (r_1 S - a h_1)$$

### 3.3 L'approche floue

$$A = r_1^2 * \text{Arccos}\left(\frac{h_1}{r_1}\right) - h_1 \sqrt{r_1^2 - h_1^2}$$

Revenons maintenant à l'exemple de la Figure 22 et cherchons le segment circulaire pour chacun des deux cercles. Exprimons pour cela  $h_1$  et  $h_2$  en fonction de la distance entre les centres  $O_1$  et  $O_2$  et les rayons de chacun des deux cercles.

$$h_1 = x_I \quad \text{et} \quad h_2 = d - x_I = \frac{d^2 + r_2^2 - r_1^2}{2d}$$

L'aire de l'intersection entre les deux disques est :

$$A_{\text{int er section}} = A(r_1, h_1) + A(r_2, h_2)$$

Avec  $A(r, h)$ , l'aire du segment circulaire du cercle de rayon  $r$  et de hauteur  $h$ , hauteur du triangle, défini par le centre du cercle et les deux points d'intersection, issue du centre du cercle.

Soit :

$$A_{\text{int er section}} = r_1^2 * \text{Arccos}\left(\frac{h_1}{r_1}\right) - \frac{h_1 a}{2} + r_2^2 * \text{Arccos}\left(\frac{h_2}{r_2}\right) - \frac{h_2 a}{2}$$

$$A_{\text{int er section}} = r_2^2 * \text{Arccos}\left(\frac{d^2 + r_2^2 - r_1^2}{2dr_2}\right) + r_1^2 * \text{Arccos}\left(\frac{d^2 + r_1^2 - r_2^2}{2dr_1}\right) - \frac{1}{2} \sqrt{4d^2 r_1^2 - (d^2 - r_2^2 + r_1^2)^2}$$

On retrouve bien la relation énoncée initialement pour le calcul de l'intersection de deux cercles. ■

L'intersection entre les deux disques, et donc, le degré d'appartenance du point au milieu représenté par le milieu sombre de rayon de courbure  $r_1$ , est donc bien fonction à la fois de la distance du point à la frontière (on peut facilement faire apparaître le terme  $d-r_1$  dans chacun des membres de l'équation) ainsi que du rayon de voisinage  $r_2$  fixé (Figure 24).

A partir de cette relation, on peut exprimer de façon littérale le degré d'appartenance d'un point  $P$  au milieu de référence pour une échelle d'observation  $R$  donnée (cf. 3.3.1.2) par la relation déduite de la relation (1) de la section 3.3.1.2:

$$ml(P, R) = \frac{\int_{r_2=0}^R A_{\text{int er section}}(r_2) * dr_2}{\int_{r_2=0}^R \pi * r_2^2 * dr_2}$$

Afin d'expliciter l'impact de la distance entre le point considéré et, la frontière d'une part puis de l'échelle d'observation d'autre part, sur la surface d'intersection entre le voisinage circulaire du point étudié et le milieu de référence, ces calculs numériques réalisés ont permis de mettre en évidence les trois résultats suivants :

- Pour une distance à l'interface donnée (la distance  $d$  entre les deux centres des disques et le rayon du milieu de référence  $r_1$  fixes et connus), les points considérés seront intérieurs au milieu de référence pour des valeurs d'échelle d'observation  $R \leq r_1 - d$  (en se restreignant aux cas  $d \leq r_1$ ). La Figure 24 est une illustration du phénomène pour  $d=13$  et  $r_1=20$  unités de mesures. On voit très nettement que pour des rayons de voisinage maximum  $R \leq 7$ , l'aire d'intersection reste identique à celle correspondant à un point intérieur à ce même milieu. Ceci s'explique par le fait que tous les éléments du voisinage du point considéré restent eux aussi inclus dans le milieu de référence. Dans le cas contraire d'une échelle d'observation  $R > 7$ , les aires de recouvrement des deux disques diffèrent et le degré d'appartenance du point considéré au milieu de référence devient inférieur à 1 ( $m_1(P,R) < 1$ ).

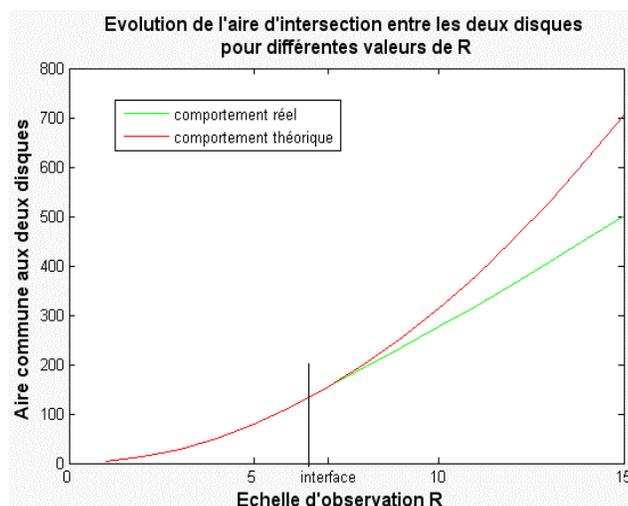


Figure 24 : Evolution de l'aire d'intersection entre deux disques pour une distance entre leurs centres respectifs  $d=13$  et le rayon du disque représentant le milieu de référence  $r_1=20$ . Tant que l'échelle d'observation reste inférieure à 7 dans notre cas, le comportement du point considéré (comportement réel en vert sur la figure) reste semblable à celui d'un point intérieur au milieu de référence (comportement théorique en rouge). Dans le cas contraire, les comportements diffèrent et le degré d'appartenance (correspondant au rapport entre les aires des surfaces délimitées par l'axe des abscisses d'une part et la courbe représentant le comportement d'autre part, pour des rayons compris entre 0 et R) du point considéré au milieu de référence devient inférieur à 1.

- Découlant directement de l'observation précédente, nous pouvons remarquer que l'épaisseur de la zone de transition séparant les deux

### 3.3 L'approche floue

milieux de référence est fonction de l'échelle d'observation à laquelle on se place. Plus  $R$  sera élevé, plus la distance entre l'interface et un point intérieur à un des milieux de référence ( $m_i(P,R)=1$ ) sera importante. La Figure 25 illustre ce fait dans le cas de la Figure 14 pour différentes valeurs d'échelle d'observation  $R$  choisies. Plus  $R$  est important, plus on rencontre tôt des points « impurs », sur le trajet  $\delta$  entre le centre du milieu de référence et l'interface. La zone de transition sera alors plus épaisse.

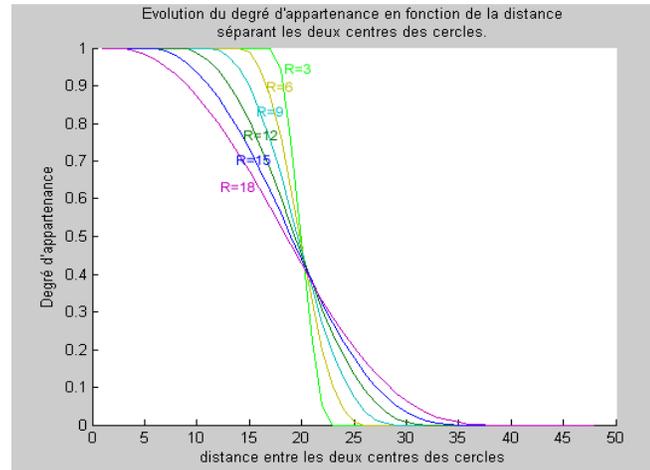


Figure 25 : Evolution des degrés d'appartenance au milieu de référence, le long de l'axe  $\delta$  de la Figure 14, en fonction de la distance au centre du disque de référence ( $r_1=20$ ). Plus  $R$  est élevé, plus la zone de transition, que l'on pourrait délimiter par le dernier point ayant un  $m_i(P,R)=1$  avant l'interface et le premier point ayant un  $m_i(P,R)=1$  après, est épaisse.

- Un autre point important que l'on peut mettre en évidence concerne le lissage de l'interface. Pour un rayon de voisinage important, de façon similaire à la perception que l'homme se ferait de l'image perçue à l'échelle d'observation, l'interface entre les deux milieux paraît floue, grossière, avec perte de détail. On assiste alors à un lissage de la zone de transition. Dans notre approche, nous avons retenu, comme appartenant à la transition, les pixels ayant un coefficient de pureté minimum. On peut alors s'intéresser au biais pouvant exister entre la transition de l'image initiale et la transition que l'on obtiendrait à différentes échelles d'observation. La Figure 26 est relative à la Figure 14, elle représente l'évolution des coefficients de pureté de points le long de l'axe  $\delta$ , en partant du centre du milieu de référence vers l'autre milieu en passant par la frontière. On remarquera la non symétrie des courbes et donc le décalage de l'abscisse du minimum des coefficients de pureté vers le milieu de référence en fonction de l'échelle d'observation. Cela peut être interprété comme une conséquence du lissage de l'interface ; lissage probablement lié à la convexité de la frontière et/ou au système de voisinage utilisé.

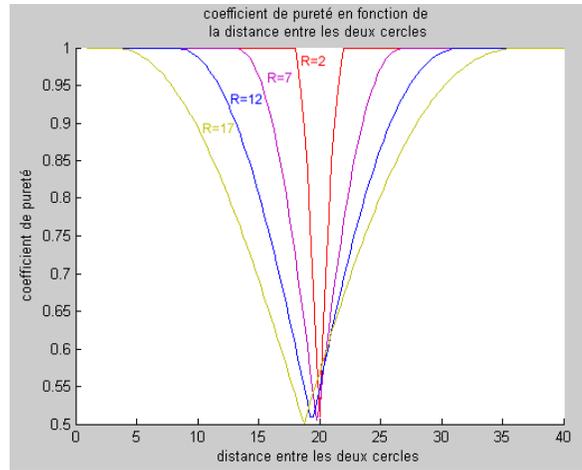


Figure 26 : Evolution du coefficient de pureté le long de l'axe  $\delta$  de la Figure 14 en partant de  $O_1$ . Chaque courbe colorée correspond à l'utilisation d'une échelle d'observation différente. On discerne qu'une augmentation de l'échelle d'observation déplace le minimum des coefficients de pureté vers le milieu de référence.

Nous vérifions ici l'influence du paramètre R sur la zone de transition ; nous assistons à un épaississement quand R augmente et donc un lissage de la zone de transition. Ce lissage peut finalement, pour des valeurs de R trop élevées, provoquer un biais sur l'estimation de la zone de transition. On retrouve l'opposition détection / localisation [Chabrier, 2005].

### 3.3.3.2 Paramètre k et complexité de l'interface observée

L'utilisation du facteur de sensibilité k présente un double intérêt :

➤ Il nous permet, comme suggéré sur la Figure 27, de modifier l'épaisseur de la zone de transition et ainsi de garantir un lissage beaucoup moins rapide de la zone de transition.

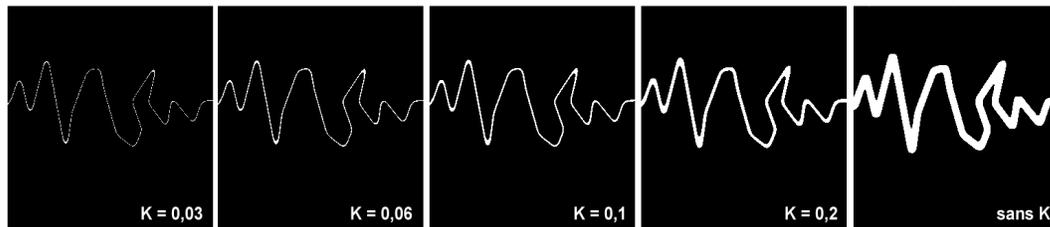


Figure 27 : Action du facteur de sensibilité k sur la zone de transition (R fixé à 8). On voit que plus le facteur de sensibilité k augmente, plus la zone de transition s'épaissit. Le dernier cas, intitulé « sans k », correspond à un cas où  $M^R + k \geq 1$ .

Ce lissage plus lent se répercute directement sur l'interface extraite. En effet, l'utilisation du facteur de sensibilité k permet la conservation, dans la limite du possible, de la complexité de l'interface. Sur l'exemple de la Figure 28, montrant les squelettes des zones de transitions obtenues à la Figure 27, un facteur k à 0,06 permet retrouver une interface proche de celle espérée contrairement au cas extrême, sans utilisation du facteur k.

### 3.3 L'approche floue

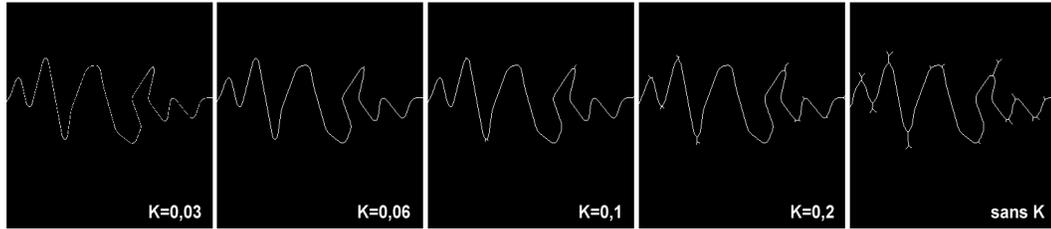


Figure 28 : Approximation des interfaces par squelettisation des diverses zones de transitions représentées à la Figure 27 ( $R$  fixé à 8). On voit très nettement qu'une faible valeur de  $k$  permet une conservation des propriétés de l'interface.

Le facteur  $k$  permet donc de conserver au maximum, à une échelle d'observation donnée, les propriétés de l'interface (complexité). Essayons maintenant d'appliquer ce résultat pour des cas d'échelles d'observation de plus en plus élevées (Figure 20). La Figure 29 reprend les transitions obtenues mais en prenant en compte un facteur de sensibilité  $k=0,1$  pour les échelles d'observation  $R=2$  et  $R=4$ ,  $k=0,05$  pour  $R=8$ ,  $k=0,03$  pour  $R=16$ , et enfin  $k=0,01$  pour le dernier cas ( $R=32$ ). Jusqu'à la valeur  $R=16$ , la zone de transition semble conserver les propriétés de l'interface attendue. Cet exemple met de plus en avant la limite de la méthode : pour une échelle d'observation trop importante, le lissage de la zone devient alors trop important pour pouvoir espérer retrouver une interface de complexité proche de celle recherchée.

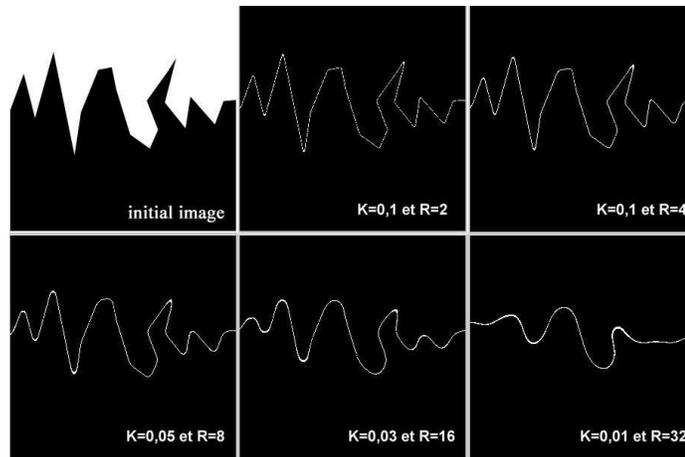
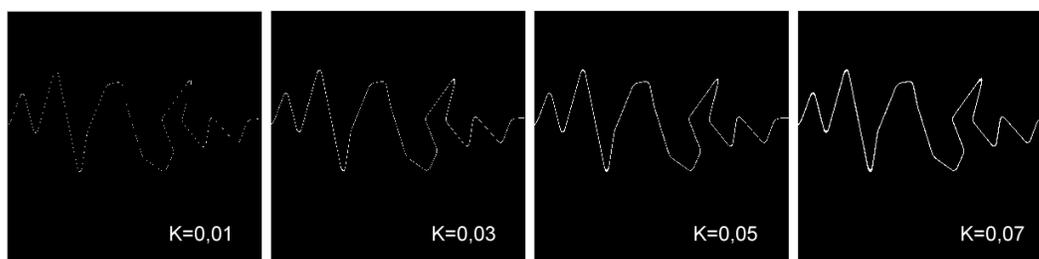


Figure 29 : Zones de transition obtenues pour diverses valeurs de  $R$  et de  $k$ . L'utilisation combinée des paramètres  $R$  et  $k$ , nous permet de conserver au maximum les propriétés de l'interfaces et ce, même pour de fortes valeurs de  $R$ .

La zone de transition réduite ainsi obtenue (Figure 29) peut être assimilée à une région incluant l'interface réelle. De plus, comme notre processus de « fuzzyfication » est isotrope, nous pouvons faire l'hypothèse que la forme de la zone de transition reflète l'allure de la zone d'interface réelle entre ces milieux. Cette hypothèse forte, vérifiée sur de nombreuses images de

synthèse, permet donc bien d'approcher l'interface réelle par le squelette de la zone de transition (Figure 28).

➤ L'utilisation du paramètre  $k$  apporte une solution au problème que peut poser la présence de discontinuités dans l'interface extraite. Elle résout le problème nécessaire dans certaines méthodes de suivi de contours. En effet, sans l'utilisation du facteur de sensibilité présenté ici, il n'est pas rare d'obtenir une zone de transition entre deux milieux présentant de nombreuses discontinuités. Elles peuvent être réalistes dans certains cas ou constituer un défaut de la méthode dans d'autres. Une alternative aux nombreuses méthodes de suivi de contours présentes dans la littérature, est directement donnée par l'utilisation du paramètre  $k$ . En effet, une augmentation de ce paramètre permet une restriction moins importante sur les coefficients de pureté des pixels appartenant à la zone de transition. Certains pixels de coefficient de pureté trop élevé initialement vont alors devenir étiquetés comme appartenant à la zone de transition et le nombre de composantes connexes de la transition sera réduit globalement.



*Figure 30 : Effets du paramètre de sensibilité  $k$  sur les discontinuités de l'interface obtenue sur la Figure 11 pour une échelle d'observation  $R=5$ . Une augmentation du paramètre  $k$  nous permet d'étendre la zone de transition aux pixels ayant un coefficient de pureté proche de ceux de la transition initiale.*

Le choix du paramètre  $k$  devient alors déterminant afin de garantir la continuité de l'interface. Un facteur de sensibilité trop faible provoquera des discontinuités dans la zone de transition extraite (Figure 30) alors qu'un facteur trop important nuira à la bonne localisation de cette zone de transition. La Figure 31 illustre l'évolution du nombre de composantes connexes composant la zone de transition en fonction du facteur de sensibilité  $k$ . L'étude correspond toujours à l'exemple de la Figure 14. Il suffit dans ce cas de prendre un  $k$  à 0,12 pour avoir une interface continue d'épaisseur minimale. Cette étude peut se généraliser sur toute image afin de définir un  $k$  optimum pour la détermination de l'interface tout en respectant les notions de continuité.

### 3.4 Approche fractale pour le calcul de la complexité

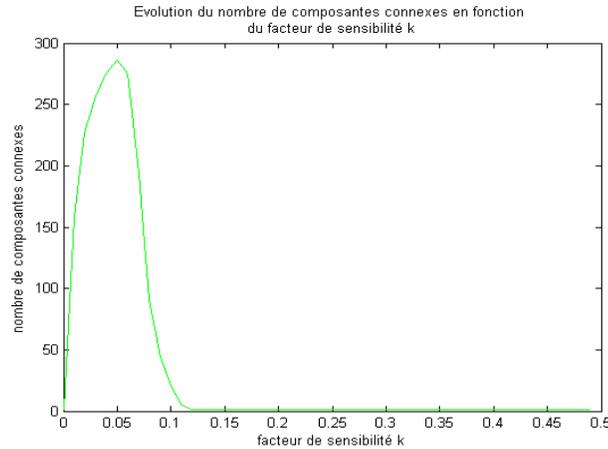


Figure 31 : Evolution du nombre de composantes connexes de la transition obtenue sur la Figure 11 à échelle d'observation ( $R$ ) fixée à 5 en fonction des valeurs du facteur de sensibilité  $k$ . Afin d'obtenir une zone de transition continue (une seule composante connexe dans notre cas), il faut choisir  $k \geq 0,12$  dans ce cas précis.

Finalement, la représentation graphique obtenue de l'interface, bien qu'approximative et grossière, permet d'obtenir, dans la limite du possible, une conservation globale des caractéristiques (irrégularité) de l'interface réelle. Reste maintenant à caractériser cette interface. Nous proposons de quantifier la complexité de cet objet par un calcul de dimension fractale.

### 3.4 Approche fractale pour le calcul de la complexité

#### 3.4.1 Approche théorique du calcul de complexité

##### 3.4.1.1 Dimension fractale d'un signal dépendant d'un seul paramètre

Mesurons la longueur d'une courbe successivement à l'aide de règles de différentes longueurs. Les mesures usuelles reposent sur l'hypothèse que plus la longueur de la règle sera petite, mieux le contour sera suivi et plus la mesure finale sera précise (Figure 32). De plus, pour une règle suffisamment petite, si l'on divise sa taille par un facteur «  $c$  »,  $c > 1$ , on utilisera la règle «  $c$  » fois plus pour couvrir l'intégralité de la courbe. On a alors un rapport  $c/c$  de 1, correspondant à la dimension des figures Euclidiennes (formes

linéaires ou courbes relevant de la géométrie classique).

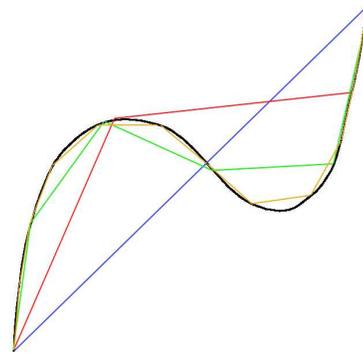


Figure 32 : Estimation de la longueur de la courbe à l'aide de règles de longueurs différentes.

A *contrario*, si l'on s'intéresse au calcul de dimension de la courbe de Von Koch présentée à la Figure 15, en subdivisant la règle en 3, on devra utiliser la nouvelle règle non plus 3 fois plus mais 4 fois plus (Figure 33). Ce qui revient à dire que pour l'utilisation d'une règle 3 fois plus petite, la longueur de la courbe mesurée est multipliée par 4/3. La dimension, donnée par la relation  $\log(4)/\log(3)$ , n'est pas égale à 1 mais à 1,26. On est donc en présence d'une figure pour laquelle la dimension fractale est supérieure à 1 et, qui plus est, non entière.

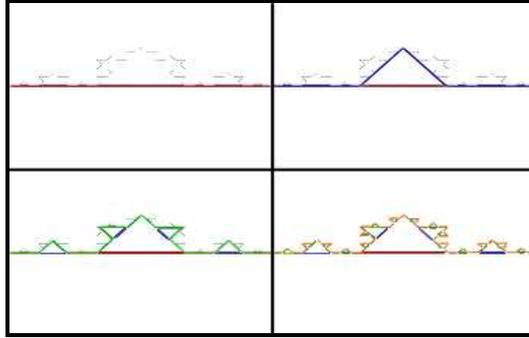


Figure 33 : Exemple de calcul de la longueur de la courbe de Von Koch à l'aide de règles de dimensions diverses.

Toutefois, la dimension des objets fractals ne peut dépasser la dimension de l'espace de plus faible dimension les incluant soit 2 (dimension des surfaces) pour les courbes ou figures géométriques dans le plan.

Il existe de nombreuses méthodes de calcul de la dimension fractale, nous présentons ici celle que nous avons adoptée : la méthode des dilatations successives.

Le calcul est basé sur la relation de Bouligand-Minkowski suivante:

$$D(X) = \lim_{r \rightarrow 0} \left[ d - \frac{\log(M(Xr))}{\log(r)} \right] \quad (1)$$

Avec :

- $M(Xr)$  la mesure d'un recouvrement minimum par des sphères de rayon  $r$ ,
- $r$  le pas de mesure dont dépend la taille de l'élément structurant,
- $d$  la dimension de l'espace métrique dans lequel est effectuée la mesure,
- $D(X)$  la dimension fractale de l'objet  $X$ .

Le problème est le calcul de  $M(Xr)$ .  $Xr$  est ici approximé par le dilaté de  $X$  dans une opération morphologique avec un élément structurant de rayon  $r$ .

Cette approche se résume donc en une succession de dilatations de la structure  $X$  étudiée. L'aire du dilaté est alors calculée entre chaque dilatation avec un élément structurant de rayon 1 ; une approximation de la dimension

### 3.4 Approche fractale pour le calcul de la complexité

fractale de l'objet initial est ensuite obtenue à partir du graphique «  $\log(A(Xr))=f(\log(r))$  ».

Prenons comme exemple le calcul de la dimension fractale d'un segment (dimension de 1) symbolisé dans une image binaire par la matrice A et l'élément structurant B carré usuel.

$$A = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

Nous dilatons alors la forme contenue dans la matrice A par l'élément structurant B un certain nombre de fois (la Figure 34 reprend les trois premières itérations du processus). Entre chacune d'entre elles, l'aire du nouvel objet ainsi obtenu (du dilaté) est calculée et stockée.

$$A1 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix}$$

$$A3 = \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

$$A5 = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}$$

Figure 34 : Évolution du dilaté obtenu par dilatactions successives du segment de la matrice A par l'élément structurant B.

Une fois les dilatactions effectuées, il ne reste plus qu'à utiliser la relation (1) pour en déduire la dimension fractale de l'objet initial, à partir du graphique «  $\log(\text{Aire})=f(\log(r))$  ». On trouve alors pour ce segment une dimension fractale de :  $D(A) = d - 1,06 = 2 - 1,06 = 0,94$ . La faible longueur du segment explique l'approximation du résultat.

On peut bien évidemment appliquer cette approche sur des images réelles telles que l'image de la Figure 35. La surface de transition proposée sur cette figure représente une ligne d'horizon dans un paysage vallonné.

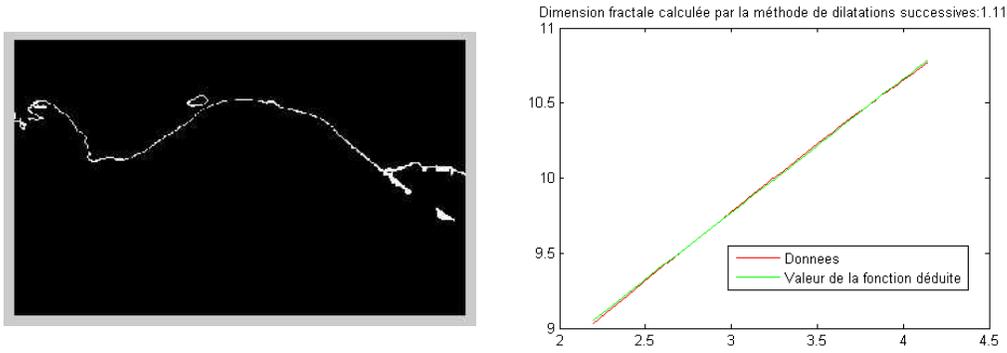


Figure 35 : Dimension fractale obtenue par la méthode des dilatations successives sur le squelette de la transition proposée à gauche : 1,11 pour un rayon de voisinage de 2

### 3.4.1.2 Dimension fractale d'une image, d'une surface

Remarque :

Le calcul de la dimension fractale d'une surface, utilisé dans le chapitre suivant, est développé ici pour conserver une certaine cohérence dans la présentation des outils.

Calculer la dimension fractale d'une surface, d'une texture, permet de quantifier sa complexité. On entend par complexité l'irrégularité entre les niveaux de gris de pixels voisins. Pour ce faire, l'image n'est plus perçue comme un plan mais comme un relief dans lequel chaque pixel initial est transformé en voxel comme représenté sur la Figure 36. On ajoute ainsi une troisième dimension appelée altitude correspondant aux niveaux de gris des pixels :  $P(x, y) \rightarrow V(x, y, ndg(x, y))$

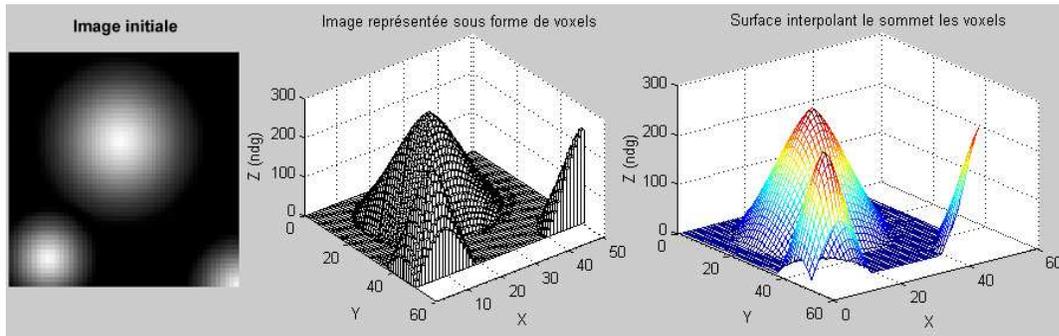


Figure 36 : Représentation sous forme de voxels d'une image numérique avant interpolation du relief par une surface

Tout comme pour l'évaluation de la dimension fractale de courbes, on dispose d'un très grand nombre d'approches dans la littérature pour estimer la complexité d'une image. Nous nous limiterons ici à la généralisation de la méthode des « dilatations successives » à la troisième dimension.

### 3.4 Approche fractale pour le calcul de la complexité

#### ➤ La méthode des « dilatations successives »

Généralisation de la méthode des dilatations décrite dans la section précédente, l'approche consiste à dilater la surface rendue continue (déduite à partir de l'ensemble des voxels de l'image) ou le volume ( $X$ ), dans l'espace  $\mathbb{R}^3$ . Pour ce faire, nous avons opté pour un élément structurant simple permettant une dilatation isotrope : un cube de taille  $3 \times 3 \times 3$  ayant pour pivot son élément central.

Suite à chaque nouvelle dilatation, on calcule le volume occupé par le nouveau dilaté  $Xr$ . Le calcul de la dimension fractale proposé par Bouligand-Minkowski étant généralisé à un espace multi dimensions (relation 1), le graphe «  $\log(V(Xr))=f(\log(r))$  » nous permet d'effectuer une estimation de la dimension fractale de l'objet initial.

La dimension fractale théorique de cette image peut alors être estimée par la relation 3-a (relation 1) où «  $a$  » est le coefficient directeur de la droite de régression linéaire qui approche le mieux le nuage de points du graphe. On trouve ici (Figure 37) une dimension fractale de 2,1.

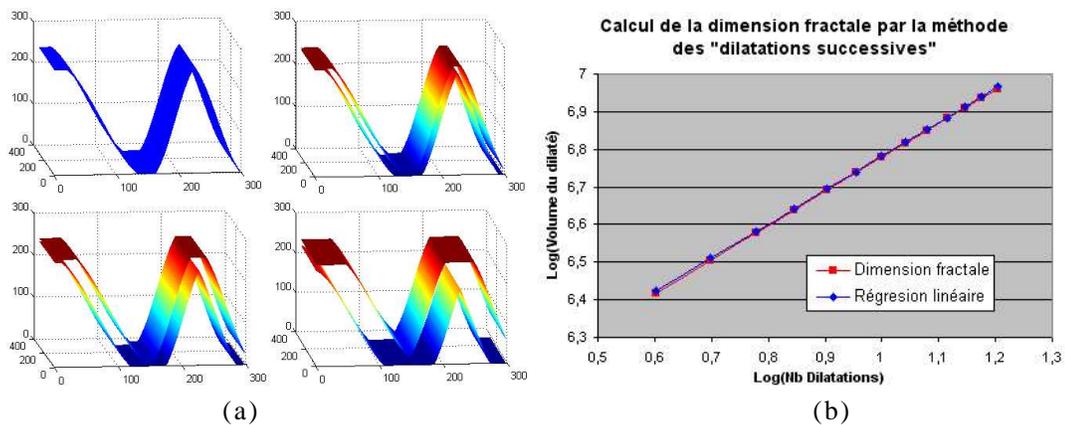


Figure 37 : Approximation de la dimension fractale de la surface en bleu via la méthode des dilatations successives.

(a) : surface initiale en bleu puis dilatés obtenus (représentés par deux surfaces, une supérieure et une inférieure au volume) après 4, 8 et 16 dilatations successives par un cube de dimension  $3 \times 3 \times 3$ .

(b) : graphique représentant «  $\log(V(Xr))=f(\log(r))$  ». La dimension observée est de 2,1.

#### 3.4.1.3 Caractérisation des interfaces dans les images synthétiques

Afin de vérifier l'approche dans un contexte général, il est souvent bon de l'appliquer sur un support dont le résultat escompté est connu. C'est dans cette logique qu'a été effectuée une campagne de tests visant à valider la méthode. Les images ainsi traitées sont des images synthétiques mettant en présence :

- soit des objets, interfaces, du domaine Euclidien (Figure 38)

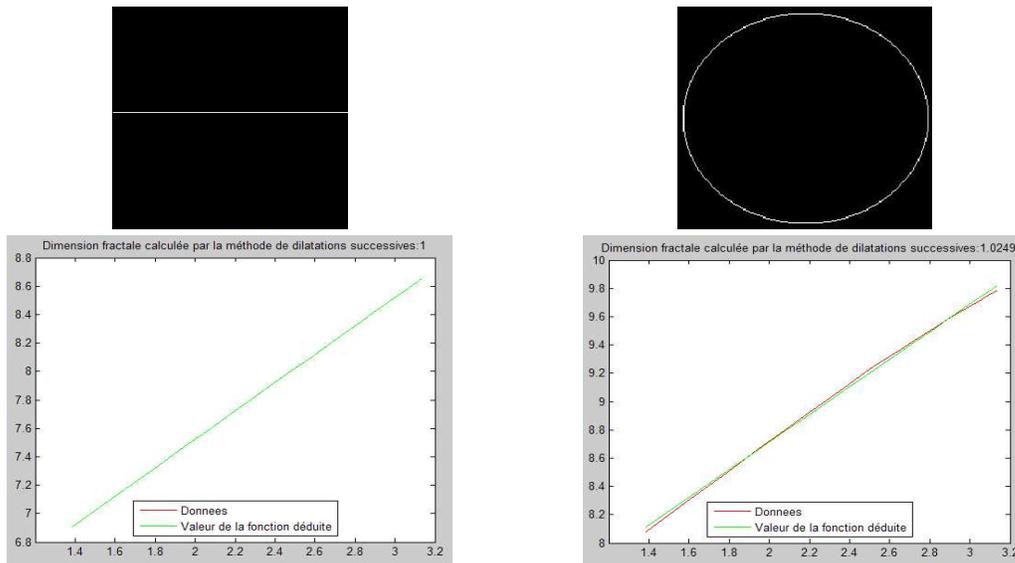


Figure 38 : Calcul de la dimension fractale de figures appartenant au domaine Euclidien. Nous obtenons ici une dimension de 1 pour l'interface horizontale et 1,0249 pour la dimension du cercle. Complexité estimée grâce à la méthode des dilations successives.

- soit des courbes fractales de dimensions connues telles que les courbes de Von Koch ou de Minkowski (Figure 39).

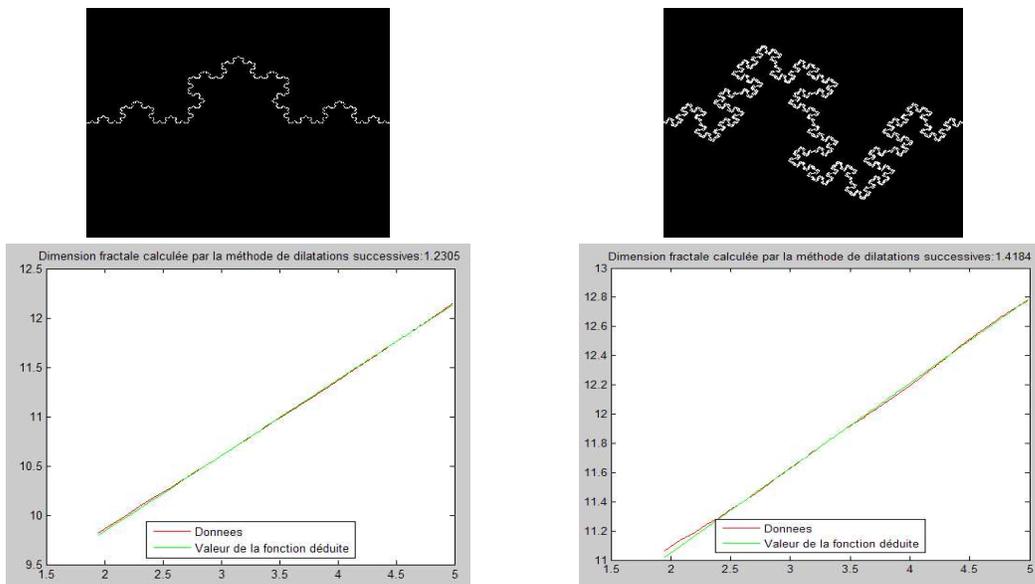


Figure 39 : Calcul, via la méthode des dilations successives, de la complexité de deux courbes fractales connues. La courbe de Von Koch à gauche et la courbe de Minkowski à droite.

Les dimensions observées (1,23 et 1,42) sur les courbes fractales de la Figure 39 sont proches des dimensions théoriques connues (1,26 et 1,5). La légère différence s'explique par le fait que la dimension théorique est donnée pour une courbe obtenue en effectuant une transformation une infinité de fois.

### 3.4 Approche fractale pour le calcul de la complexité

Or, pour des raisons de temps de calcul mais aussi de précision au sein de l'image (limitée à la résolution du pixel), le processus de construction des fractales synthétiques ne dépasse que rarement quelques douzaines d'itérations. La courbe fractale synthétisée est alors moins complexe que la courbe théorique de dimension connue, sa dimension fractale est donc légèrement inférieure à la dimension théorique. De plus, le changement d'échelle effectué via le paramètre « R » va altérer le résultat escompté en lissant la courbe extraite correspondant à l'interface. Plus R sera élevé, plus la dimension fractale sera faible (sauf figures appartenant au domaine Euclidien) comme présenté sur la Figure 40.

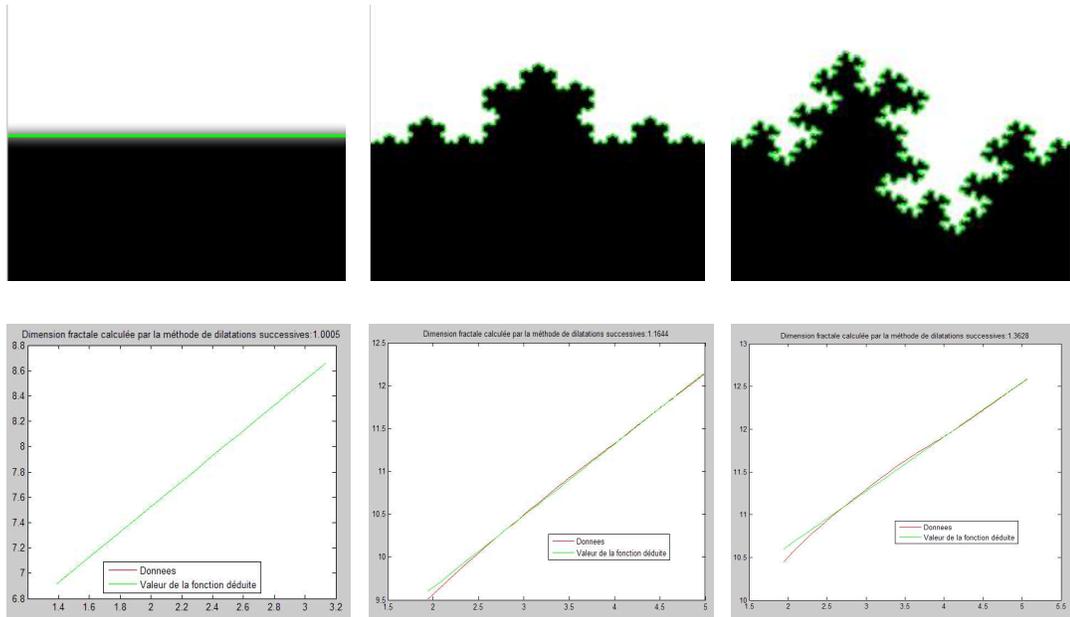


Figure 40 : Calcul des dimensions fractales des interfaces obtenues sur différentes images synthétisées (avec  $R=5$  et  $k=0,03$ ) via la méthode des dilations successives :

- Image de gauche => dimension de 1 (domaine Euclidien)
- Image du centre (courbe de Von Koch) => dimension de 1,16
- Image de droite (courbe de Minkowski) => dimension de 1,36

Sur les exemples de la Figure 40, la dimension fractale augmente progressivement avec la complexité structurelle intuitive des cas étudiés. On se rend alors compte de la possibilité qu'offre l'approche fractale, par le biais du calcul de la dimension des objets, pour quantifier la complexité d'une structure. Afin de compléter l'analyse et généraliser la méthode, l'étude d'une interface connue entre deux milieux fortement texturés est présentée dans la section suivante. Il s'agit ici d'une première généralisation de notre approche présentée jusqu'ici par rapport à des milieux clairs et sombres.

#### 3.4.2 Interface entre deux milieux texturés

Les images présentées ici sont synthétisées à partir de textures recensées dans l'ouvrage de Brodatz [Brodatz, 1966]. Nous nous limitons ici à la

caractérisation de l'interface entre deux textures uniquement. On peut alors distinguer deux cas :

➤ Les deux milieux sont discernables visuellement

La nuance de gris moyenne des deux milieux est alors globalement différente. Dans ce cas, en se plaçant à une échelle d'observation ( $R$ ) suffisante les deux milieux sont perçus comme non texturés (plus uniformes).  $R$  doit être pris assez grand pour prendre en compte la granularité de la texture (dimensions du voisinage supérieures aux dimensions du motif de base constituant la texture). Une augmentation de ce paramètre  $R$ , nous permet en effet d'homogénéiser les textures. La Figure 41 et la Figure 42 montrent deux exemples de caractérisation d'interfaces entre deux milieux texturés.

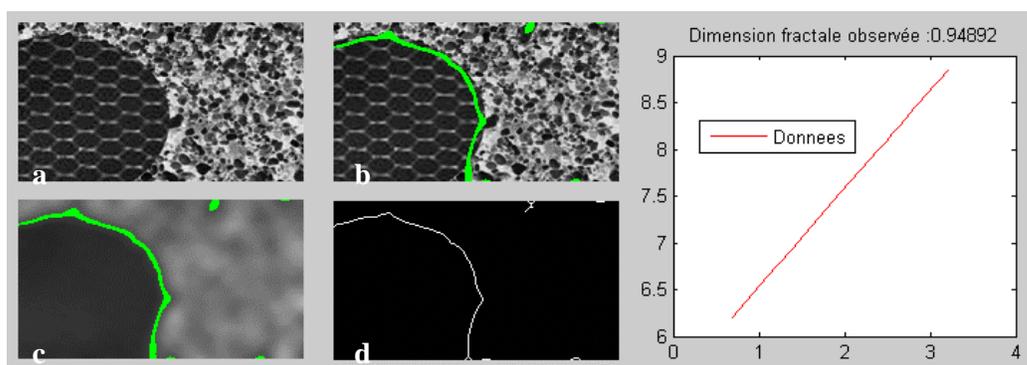


Figure 41 : Dimension fractale estimée de l'interface entre deux milieux texturés ( $R=12$  et  $k=0,03$ ) de l'image (a).

*b* : image initiale sur laquelle nous avons superposé la transition estimée

*c* : perception de l'image à une échelle d'observation  $R=12$  et transition obtenue

*d* : estimation de l'interface par le squelette de la zone de transition

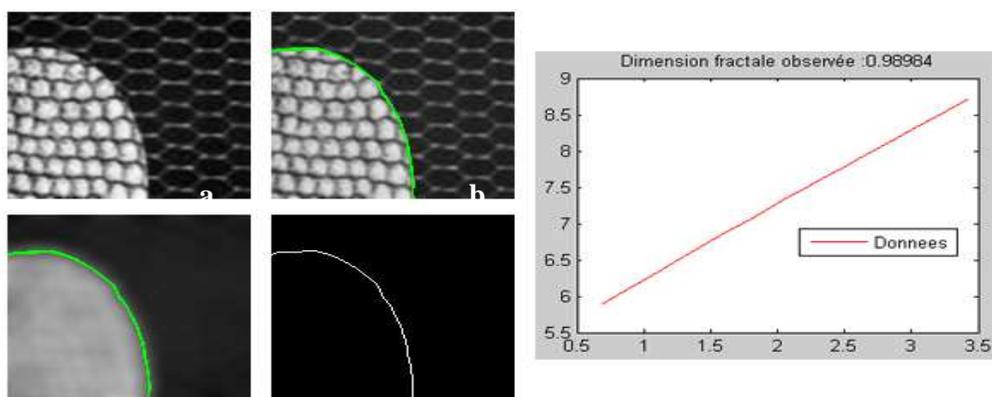


Figure 42 : Autre exemple d'estimation de la dimension fractale d'une interface entre deux milieux texturés ( $R=12$  et  $k=0,03$ ) de l'image (a).

*b* : image initiale sur laquelle nous avons superposé la transition estimée

*c* : perception de l'image à une échelle d'observation  $R=12$  et transition obtenue

*d* : estimation de l'interface par le squelette de la zone transition

### 3.4. Approche fractale pour le calcul de la complexité

➤ Les deux milieux ont une texture très proche visuellement

Cette similarité empêche alors toute utilisation de méthodes basées sur l'analyse de l'histogramme des niveaux de gris. On se tourne alors vers une étude structurelle des textures (répartition des pixels au sein de la texture). La littérature propose un certain nombre d'approches pour la modélisation de textures (analyse probabiliste à l'aide de champs de Markov, utilisation de matrice de co-occurrence ou encore calcul de vecteurs moments représentatifs de la structure). La spécificité de toutes ces approches réside dans une phase dite « d'apprentissage », au cours de laquelle une modélisation des textures des milieux en présence est effectuée.

Nous avons opté ici pour l'utilisation de l'analyse par calcul de vecteurs moments. Cette méthode, facile à mettre en œuvre, nous permet de valider l'utilisation d'une des approches proposées ici comme précurseur de notre algorithme. La finalité de cette étape sera de retrouver une matrice de coefficients de pureté à partir de vecteurs moments calculés en tous les points de l'image.

Principe :

- A chaque pixel est alors associé un vecteur regroupant les moments calculés sur son voisinage (analyse locale) :

$$P(x, y) \rightarrow \text{VectMom}P(x, y, 1:n)$$

Ce vecteur rassemble les moments d'ordre 1 à n. Dans la pratique, le calcul des 4 premiers moments (la moyenne, la variance, l'asymétrie et le coefficient d'aplatissement) est suffisant.

- Vient ensuite la phase d'apprentissage. On extrait alors de chacun des deux milieux connus un vecteur moments caractéristique : P à changé car point

$$\text{VectMomentsMilieu1} \quad \text{et} \quad \text{VectMomentsMilieu2}$$

- L'étape suivante consiste, pour chaque pixel de l'image, en un calcul de distance entre le vecteur moments calculés sur le voisinage et les deux vecteurs moments de référence :

$$d(\text{VectMom}P, \text{VectMomentsMilieu1}) \quad \text{et} \quad d(\text{VectMom}P, \text{VectMomentsMilieu2})$$

- Un calcul de coefficient de pureté est alors effectué en appliquant la relation :

$$c(P, R) = \max \left( \frac{d(\text{VectMom}P, \text{VectMomentsMilieu1})}{\text{DistEntreMilieux}}, \frac{d(\text{VectMom}P, \text{VectMomentsMilieu2})}{\text{DistEntreMilieux}} \right)$$

Avec

$$DistEntreMilieux = d(VectMomP, Milieu1) + dVectMomP, VectMomentsMilieu2)$$

- Il ne reste plus qu'à appliquer le reste de l'algorithme proposé précédemment sur la matrice des coefficients de pureté. L'interface entre les deux milieux est tout d'abord extraite avant d'être caractérisée.

Un exemple de cet algorithme est repris ici sur une image synthétisée à partir d'images extraites de l'album de Brodatz. L'image, bien qu'intuitivement segmentable, rend impossible l'utilisation de la méthode basée sur les degrés d'appartenance développée en section 3.3.1.2. L'allure globale de l'histogramme des niveaux de gris de l'image nous conforte dans l'idée d'une extraction difficile des divers milieux en présence (Figure 43).

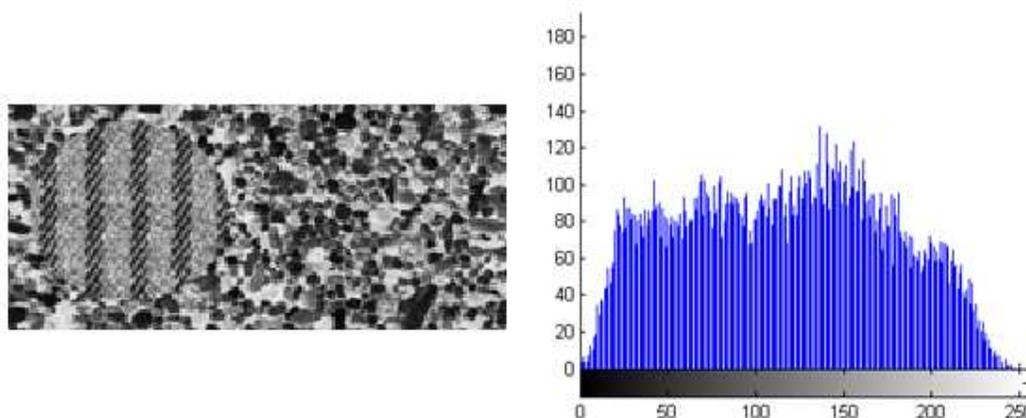


Figure 43 : Image initiale et l'histogramme des niveaux de gris correspondant.

On applique alors le prétraitement basé sur la connaissance *a priori* des deux milieux de référence. Le calcul des vecteurs moments nous permet de calculer une matrice de coefficients de pureté et de reprendre l'algorithme global présenté dans ce chapitre. La Figure 44, représente la transition et les milieux obtenus pour une échelle d'observation  $R=19$  et pour paramètre de sensibilité  $k=0,03$ .

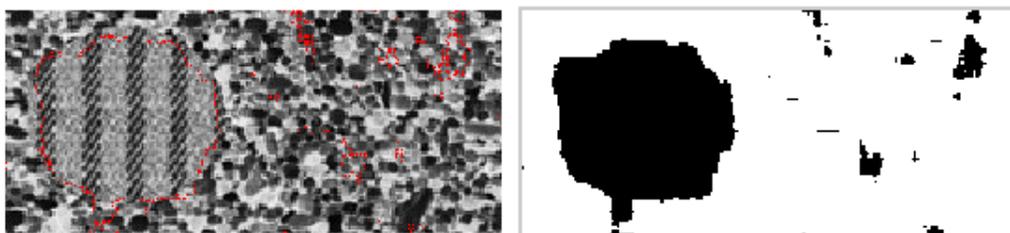


Figure 44 : Transition obtenue (en rouge) à partir des coefficients de pureté de l'image et extraction des deux milieux de référence.

### 3.4. Approche fractale pour le calcul de la complexité

La dernière étape consiste à quantifier la complexité de l'interface ainsi obtenue (Figure 45).

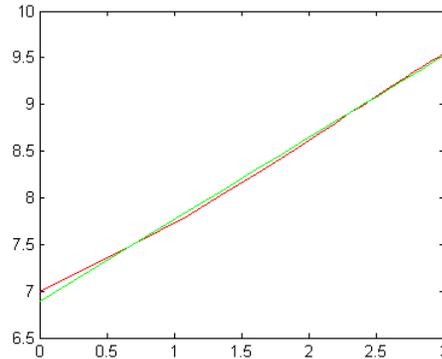


Figure 45 : Dimension fractale estimée par la méthode des dilatations successives : 1,12. En rouge figurent les données et en vert la régression linéaire.

La dimension fractale trouvée de 1,12 correspond à une approximation correcte de la réalité (proche de 1). La légère surestimation pouvant être expliquée par les artefacts présents dans la zone de transition extraite. La méthode permet ainsi de caractériser l'interface entre deux milieux texturés connus et ce, grâce à l'échelle d'observation.

Nous allons maintenant appliquer la méthode sur des images réelles (ultrasonores) de milieux et interfaces inconnus.

#### 3.4.3 Approche « pratique » : application aux images ultrasonores

Expérimenter la méthode sur des images de synthèse permet de vérifier son bon fonctionnement quant à l'estimation de la complexité des interfaces. Cette étape de validation effectuée, nous pouvons passer à l'étude plus complexe des images ultrasonores. Contrairement aux images synthétiques, ces images sont bien souvent composées de plus de deux milieux pouvant correspondre à des teintes très proches (on ne sera que très rarement en présence de deux milieux fortement contrastés). Nous ne présenterons ici que des images réelles, prélevées *in vivo*, mettant en scène 2 milieux. Le cas multi milieux étant plus amplement développé dans le chapitre suivant.

La première étape nécessaire à l'extraction des transitions et interfaces de l'image, est l'identification des milieux en présence. Cette phase est basée sur une étude de l'histogramme des niveaux de gris. Deux des méthodes les plus fréquemment utilisées dans la littérature ont alors été envisagées : une méthode basée sur une étude de gradients (section 4.3.1.1) ou encore l'utilisation d'un algorithme génétique (détaillé en section 4.3.1.2) permettant de trouver les paramètres de Gaussiennes (Figure 46) dont la superposition approche le mieux l'histogramme des niveaux de gris.

De plus, afin d'améliorer la lisibilité des résultats au sein de l'image, un recalage linéaire de l'histogramme est effectué. Cela correspond à normaliser les niveaux de gris (ndg) de l'image compris initialement dans  $[ndg1, ndg2]$ , avec  $ndg2 > ndg1$ , dans l'intervalle  $[0, 255]$ .

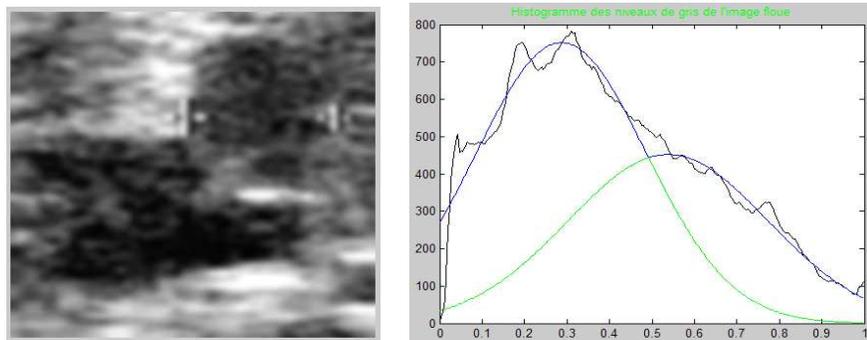


Figure 46 : Approximation de la courbe représentant l'histogramme des niveaux de gris de l'image de gauche par superposition de Gaussiennes. Chacune des deux courbes de Gauss, respectivement de paramètres  $(A_1, \mu_1, \sigma_1^2)$  et  $(A_2, \mu_2, \sigma_2^2)$ , est une approximation d'un des deux milieux en présence.

Les deux milieux étant identifiés, la transition les séparant peut alors être extraite en utilisant le processus, basé sur la logique floue, présenté précédemment sur les images synthétiques ; c'est-à-dire la détermination des coefficients de pureté des pixels constituant l'image vis à vis des deux milieux.

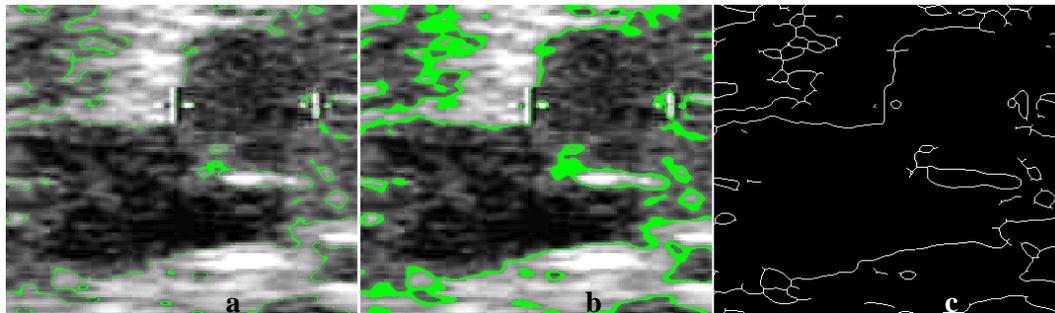


Figure 47 : Transitions obtenues sur l'image de la Figure 46 pour une échelle d'observation  $R=5$  et différentes valeurs du facteur de sensibilité  $k$  (respectivement 0,01 et 0,05 pour les cas a et b). L'élévation du facteur  $k$  nous donne des zones de transition plus épaisses et répond au problème de discontinuité des interfaces. L'image c représente l'interface obtenue pour le cas de l'image b ( $k = 0,05$ ).

Le squelette de cette zone de transition (Figure 47) nous donne alors une estimation de l'interface réelle séparant les deux milieux de référence ; interface que l'on va alors chercher à caractériser par estimation de sa dimension fractale via l'utilisation de la méthode définie précédemment.

Sur l'image étudiée (Figure 47), on obtient une dimension de l'ordre de 1,45 (Figure 48). Bien évidemment, le calcul de la dimension de l'interface réelle ne pouvant être effectué, nous n'avons aucun moyen de vérifier la véracité du

### 3.5. Conclusion

résultat. Cependant, la précédente phase de validation sur les images représentant des courbes de dimensions connues nous permet de faire confiance à ce résultat.

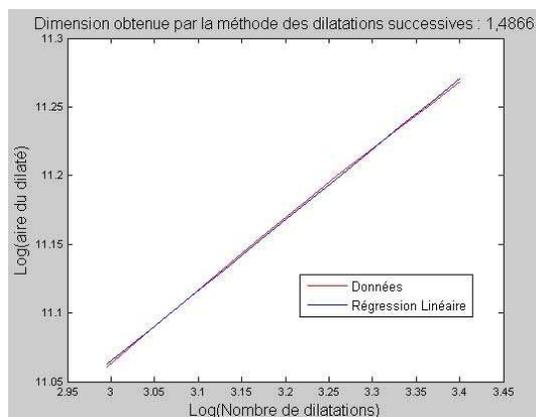


Figure 48 : Dimension fractale approchée de la courbe de la Figure 47 par la méthode des dilatations successives. Dimension observée : 1,4866

### 3.5 Conclusion

Dans ce chapitre a été développé un algorithme basé sur les approches floue et fractale. Il répond à la double problématique d'analyse structurale et de diagnostic posée initialement. Prenant en compte les spécificités de la perception humaine, notre approche nous permet de caractériser, via un calcul de complexité, une interface entre deux milieux sans pour autant être en mesure de la localiser formellement dans l'image. Une telle indication peut par exemple renseigner le spécialiste médical sur la surface d'échange entre deux milieux (cette propriété étant elle-même souvent liée à la perméabilité de l'interface vis-à-vis de substances ou de médicaments).

Notre méthode présente de plus l'avantage de ne posséder que très peu de paramètres conditionnant le résultat obtenu. Ils sont en fait au nombre de deux : le facteur d'échelle maximum  $R$  et le facteur de sensibilité  $k$ . L'échelle d'observation est choisie ni trop petite, de façon à homogénéiser suffisamment les divers milieux en présence, ni trop grande, de façon à limiter au maximum le lissage global engendré sur l'image (perte de détails). Ce lissage de l'image génère une perte de détails, au niveau des transitions notamment, qui va diminuer rapidement la complexité apparente des objets présents et ainsi interdire toute mesure de cette caractéristique. La solution envisagée a été l'introduction d'un facteur de sensibilité  $k$ . Ce facteur permet en effet de « ralentir » le lissage des transitions présentes dans l'image et ainsi conserver le plus longtemps possible leurs propriétés. D'une manière très synthétique, on pourrait dire que l'échelle d'observation  $R$  lisse les transitions de l'image alors que le paramètre  $k$  joue uniquement sur leurs épaisseurs. Ce facteur présente tout son intérêt lors de l'estimation des interfaces par squelettisation des zones de transition.

Suite à une phase de validation de la méthode sur des images représentant des interfaces de dimension connue, nous nous sommes limité ici à l'analyse d'images (ultrasonores, texturées) composées de deux milieux uniquement. Une généralisation de la méthode à des images multi milieux sera présentée dans le chapitre suivant. Le chapitre 4 débute néanmoins par la démonstration d'un lien existant entre les approches floue et fractale développées ici. Cette étape nous permettra de progresser dans l'analyse et de nous affranchir du bruit (du flou) présent initialement dans l'image. Nous finirons enfin par la présentation d'applications possibles de la méthode dans différents domaines tels que la segmentation et la compression d'images.

## Chapitre 4

# 4 Mise en œuvre théorique et pratique

---

Dans une application pratique, une image ultrasonore est par nature bruitée et composée de plusieurs milieux. Le médecin recherche dans cette image à différencier les régions, à analyser et à associer à chaque entité des caractéristiques afin de réunir les éléments lui permettant d'établir un diagnostic. Motivé par la variabilité de l'expertise dans l'analyse d'images ultrasonores, notre démarche est de mettre en place un outil permettant de s'affranchir du bruit. Cela permet de proposer une analyse quantitative des composantes de l'image : interfaces, régions et textures.

La présence de bruit perturbant les diverses approches classiques d'analyse d'images, nous avons adopté une démarche permettant de le prendre en considération. Cela est rendu possible par la mise en évidence du lien entre les approches floue, nécessaire à l'obtention des divers objets de l'image, et fractale, permettant leur caractérisation.

Ainsi, le partitionnement de l'image, obtenu par l'approche floue, bien qu'initialement non développé pour la segmentation, répond au problème de classification recherché par le spécialiste médical. Cette phase conduit naturellement à l'évaluation du partitionnement et à la comparaison avec des méthodes classiques de segmentation.

Le partitionnement validé, l'extraction des caractéristiques des milieux et des interfaces dans une image bruitée, par le calcul de leurs dimensions fractales, constitue une étape essentielle pour les objectifs d'aide au diagnostic et de compression des objets composant l'image ; ces objets peuvent être uniformes ou texturés.

---



## 4.1 Introduction

Comme détaillé au chapitre précédent, nous pouvons caractériser la complexité d'une interface dans une image composée de deux milieux. Cette étape peut être utilisée dans divers domaines. Avant de présenter des applications pratiques de la méthode, nous allons démontrer l'existence d'un lien entre les approches floue et fractale. La mise en évidence de cette dépendance permet de s'affranchir du bruit de l'image initiale. Il devient alors envisageable d'estimer les caractéristiques d'une interface réelle à partir d'une image bruitée comprenant ces 2 milieux.

D'autre part, la généralisation de notre approche est effectuée sur des images réelles composées de « n » milieux ( $n > 2$ ), et permet d'obtenir une segmentation de l'image bruitée. Des résultats obtenus sur des images ultrasonores sont ensuite évalués par comparaison avec d'autres segmentations obtenues par application de méthodes traditionnelles. En se basant sur le calcul des complexités des différentes zones extraites, chaque élément de la scène peut être compressé indépendamment. Le taux de compression sera ajusté en fonction de la complexité des éléments rencontrés.

Finalement, avant de conclure sur l'apport global de nos travaux, nous replaçons le développement de notre approche dans son contexte : la continuité des thèmes de télé échographie robotisée (projet OTELO par exemple). Les apports de la méthode sont détaillés, aussi bien pour l'aide au diagnostic, que pour une future compression d'images basée, elle aussi, sur la segmentation proposée.

## 4.2 Lien entre les approches floue et fractale

Comme démontré à la section 3.3.3, une augmentation de l'échelle d'observation ( $R$ ), consistant à augmenter la taille du voisinage avec lequel chaque pixel de l'image interagit, induit une diminution de la complexité des interfaces observées à cette échelle. L'existence d'un lien entre l'échelle d'observation et la complexité des interfaces paraît alors possible. Afin de déterminer cette relation, nous effectuons, dans un premier temps, une estimation du taux de pureté global de l'image. Une fois cet indice quantifié, la mise en correspondance entre son évolution et celle de la complexité des interfaces pour différentes valeurs de  $R$ , va nous permettre d'exprimer le type de lien les unissant.

### 4.2.1 Calcul du taux de flou de l'image observée

Le taux de flou d'une image est un indice appartenant à l'intervalle  $[\frac{1}{2} ; 1]$ . Il permet de quantifier l'indécision de classification des pixels de l'image. La classification peut être vue comme une affectation d'un pixel à une classe (pouvant être un milieu) selon un critère prédéfini comme, par exemple, la distance entre le niveau de gris du pixel et le niveau de gris moyen de la

classe. Le taux de flou prend la valeur 1 lorsque la partition est nette et sans ambiguïté. La valeur ½ correspond au pire des cas, celui où tous les éléments de la partition ne peuvent être associés à l'un ou l'autre des milieux ; leurs degrés d'appartenance aux deux milieux sont alors égaux et de valeur ½.

Il existe actuellement de nombreuses façons de calculer le taux de flou d'une partition [Huet et Philipp, 1998] [Zahid et al., 1999]. Parmi elles on retiendra, pour sa simplicité d'implémentation, l'indice T calculé comme suit:

$$T = \frac{1}{n} \text{Trace}[{}^tU U]$$

Avec :

- « n » le nombre d'éléments de la partition à évaluer.
- « U » une matrice comportant n colonnes et un nombre de lignes égal au nombre de classes de la partition. Elle contient les degrés d'appartenance des pixels aux différentes classes.

Pour notre application, nous proposons d'utiliser cet indice mais de façon plus locale, sur chaque colonne de l'image. Un taux de flou global de l'image pourra par la suite être obtenu à partir de ces taux de flou calculés pour chaque colonne. Cet indice, calculé le long des colonnes de l'image, n'a de sens que si l'interface est globalement horizontale entre les deux milieux. Si tel n'était pas le cas, une simple rotation de l'image nous permettant de retrouver cette condition est appliquée. On a alors sur chaque colonne l'apparition des deux milieux. Cela rend possible une classification des pixels de la colonne en deux classes :

- Celle des milieux constituant l'image,
- Celle des transitions (zone d'échanges) entre ces divers milieux.

Bien évidemment, plus la classification proposée est floue, plus les zones de transition sont épaisses.

On obtient donc, pour chacune des colonnes j de l'image et à une échelle d'observation R, l'indice :

$$T_j(R) = \frac{1}{n} \text{Trace}[{}^tU_j U_j]$$

Avec:

- « n » le nombre de pixels de la colonne j.
- « U<sub>j</sub> » une matrice 2\*n contenant les degrés d'appartenance des pixels aux différents milieux de référence, calculée pour une échelle d'observation R.
- R, l'échelle d'observation. Elle influe sur la taille du voisinage défini en chaque pixel et donc directement sur la matrice des degrés d'appartenance U<sub>j</sub>.

## 4.2 Lien entre les approches floue et fractale

A partir de l'indice de taux de flou  $T_j(R)$  précédent, calculé sur chacune des colonnes de l'image, nous pouvons obtenir un taux de flou plus global correspondant à celui de l'image tout entière. Pour ce faire, nous avons retenu comme indice pour l'image entière  $T^R$ , le minimum des taux de flou ( $T_j(R)$ ) obtenus sur les colonnes étudiées :

$$T^R = \min_i T_i(R)$$

Lorsque l'interface est nette, définie par une courbe de dimension 1, le taux de flou  $T^R$  est proche de 1. Cet indice peut bien évidemment être calculé pour différentes valeurs d'échelle d'observation  $R$  impliquant une variation sur les zones d'influence des pixels.

### 4.2.2 Lien entre le taux de flou et la complexité des interfaces

Sur la Figure 49b sont représentées les diverses mesures de dimension fractale calculées sur la transition séparant les deux milieux de référence (noir et blanc) de la Figure 49a en faisant varier l'échelle d'observation  $R$  (donc la précision des détails dans l'image). L'impact d'une telle modification de l'échelle d'observation va transparaître dans le calcul du coefficient de pureté global de l'image (via notamment l'augmentation du nombre de pixels non intérieurs à un milieu par épaissement de la transition). On obtient ainsi un ensemble de couples (dimension fractale calculée, coefficient de pureté) associés à une image.

Le nuage de points ainsi obtenu présente la particularité d'être globalement linéaire et représenté par une droite obtenue par régression linéaire. La dimension fractale théorique de l'objet étudié peut alors être assimilée au coefficient directeur de la droite de la régression linéaire qui approxime le mieux le nuage de points auquel vient s'ajouter son ordonnée à l'origine. Pour exemple, une dimension fractale de 1,26 est ainsi obtenue pour l'étude de la courbe de Von Koch présentée en Figure 49 ; cette valeur est une bonne approximation de la dimension théorique égale à  $\log(4)/\log(3)$ . Dans le cas d'une séparation franche entre deux milieux, selon une courbe classique, la dimension fractale théorique serait de l'ordre de 1.

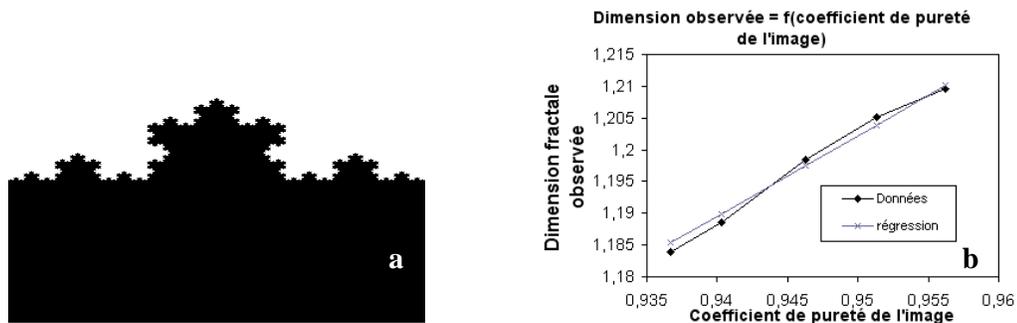


Figure 49 : Relation graphique (b) entre la dimension fractale observée de l'interface et le coefficient de pureté de l'image pour différentes valeurs d'échelle d'observation  $R$  à partir de l'image représentant la courbe de Von Koch (a).

Nous en sommes arrivés à la conviction qu'il existe donc bien une relation entre la complexité de l'interface présente entre deux milieux de référence et le taux de flou global de l'image étudiée tel que nous venons de le définir dans la section précédente. De nombreuses expérimentations sur des images synthétiques de dimensions fractales connues (courbes de Von Koch, de Minkowski et de l'espace cartésien), nous confortent dans le choix de la relation fondamentale suivante, qui nous est apparue expérimentalement :

$$Dim_o^R = Dim_{th} \cdot T^R + Cste \quad (2)$$

La relation (2) exprime le lien entre la mesure de la dimension fractale de l'interface observée à l'échelle d'observation R ( $Dim_o^R$ ) et la mesure du coefficient de pureté de l'image  $T^R$ . Lorsque la dimension théorique est inconnue, cette relation permet son estimation à partir de la dimension fractale observée de l'interface et du taux de flou de l'image.

Il est alors possible d'estimer la dimension fractale théorique d'un objet à partir d'une image de celui-ci.  Néanmoins, cette première relation ne prend pas en compte le fait que l'image initiale peut être initialement floue et ne pas contenir les caractéristiques intrinsèques de l'objet observé. Dans ce cas, l'image nécessite un prétraitement. Dans le but de déterminer le coefficient de pureté de l'image, nous avons besoin de définir deux indices :

- $T_{ini}$ , le coefficient de pureté de l'image  $I_0$  acquise initialement sans aucun prétraitement ; il correspond au calcul du coefficient de pureté pour une image  $I_0$  observée à une échelle d'observation  $R=0$ .
- $T^R$ , le coefficient de pureté calculé pour  $I_0$  mais en se plaçant à l'échelle d'observation R ( $R>0$ ).

On définit alors un troisième indice  $T^R_{normalisé}$  comme le rapport des deux taux introduits précédemment :

$$T^R_{normalisé} = \frac{T^R}{T_{ini}} \quad (3)$$

Il permet de prendre en compte le bruit (flou) initial présent dans l'image acquise par le système de capture, ce que ne permettaient pas les indices précédents. De plus, via le calcul des coefficients de pureté, il est possible de définir une interface (le squelette de la zone de transition) pour chaque échelle d'observation souhaitée. La dimension fractale observée est alors calculée pour une valeur R bien définie.

## 4.2 Lien entre les approches floue et fractale

La Figure 50 montre l'évolution de la dimension fractale observée en fonction de ce paramètre R. Chacune des courbes représentées dans une couleur particulière correspond à une image donnée.

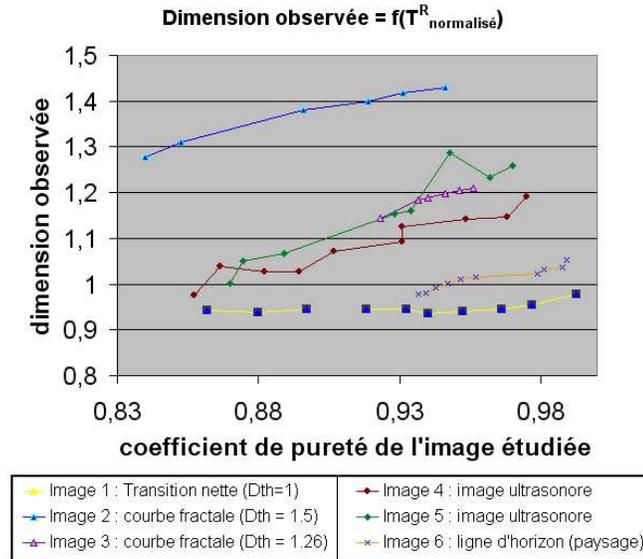


Figure 50 : Évolution de la dimension fractale de l'interface étudiée en fonction du coefficient de pureté de l'image initiale. Les variations du coefficient de pureté de l'image initiale sont obtenues en faisant varier l'échelle d'observation R.

Les images considérées dans le cas de la Figure 50 possèdent des caractéristiques différentes, induisant quelques écarts de comportement. Globalement, la dimension théorique des courbes ainsi étudiées est obtenue pour un coefficient de pureté  $T^R$  proche de 1 (induisant une échelle d'observation  $R=0$ ). Cette observation peut se traduire par l'expression suivante :

$$Dim_o^R = Dim_{th} \cdot T_{Normalisé}^R + Cste \quad (4)$$

Ce nouvel indice  $T_{Normalisé}^R$  permet donc d'approcher la dimension fractale de l'interface étudiée et cela, quel que soit le flou initial présent dans l'image.

### 4.2.3 Complexité d'une interface réelle à partir d'une image bruitée

Dans cette section, nous allons chercher à passer outre le flou (le bruit) initialement présent dans une image pour pouvoir caractériser l'interface équivalente à celle présente dans l'image où l'acquisition n'aurait pas introduit de bruit (interface réelle).

Pour cela, nous mettons en application les relations obtenues précédemment sur des courbes de dimensions théoriques connues. Puis, nous caractérisons une interface présente dans une image initialement bruitée avant de terminer sur un exemple plus concret : une image ultrasonore.

### 4.2.3.1 Courbe de dimension connue dans une image initialement nette

Bien que la méthode ne se restreigne pas aux courbes de Von Koch et de Minkowski, comme illustré sur d'autres courbes fractales de dimensions échelonnées dans l'intervalle  $[1, 2[$  en Annexe, nous ne retenons dans ce paragraphe que deux exemples ayant servi de support jusqu'à présent (Figure 51 et Figure 52). Leurs dimensions fractales respectives connues sont 1,5 et 1,26. Les images étant initialement nettes,  $T_{ini} = 1$ . A partir de la formule (3), on obtient la relation :  $T_{normalisé}^R = T^R$ . La relation (4), alors équivalente à la relation (2), nous donne donc directement la dimension théorique recherchée. La dimension théorique étant obtenue théoriquement pour une image sans bruit donc non floue, une estimation de la dimension théorique peut être obtenue par la valeur de l'ordonnée de la droite de régression linéaire approximant le nuage de points à l'abscisse  $T^0=1$ . Cela revient alors à additionner le coefficient directeur  $a$  et l'ordonnée à l'origine  $b$  de la régression linéaire. On obtient une dimension approchée de l'ordre de 1,514 pour la courbe de Minkowski et 1,27 pour la courbe de Von Koch. Ces deux approximations restent proches des valeurs théoriques connues.

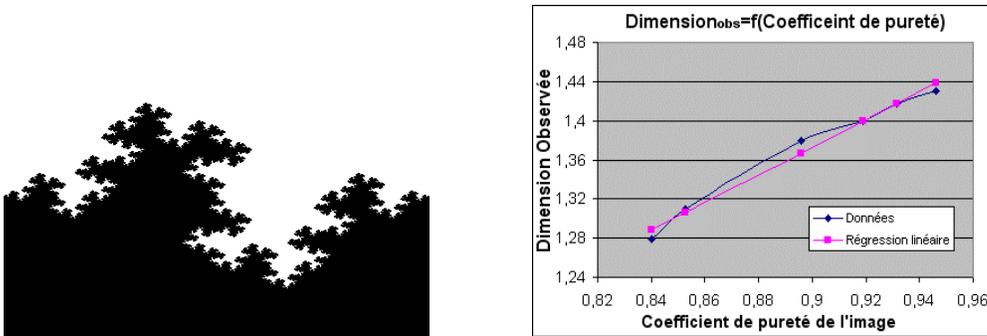


Figure 51 : Courbe de Minkowski et graphique représentant l'évolution de la complexité de l'interface en fonction du coefficient de pureté de l'image traitée (fonction de  $R$ ). Les paramètres de la droite de régression linéaire d'équation  $y=ax+b$  approximant le mieux les points obtenus nous permet d'effectuer une estimation de la dimension théorique : 1,514.

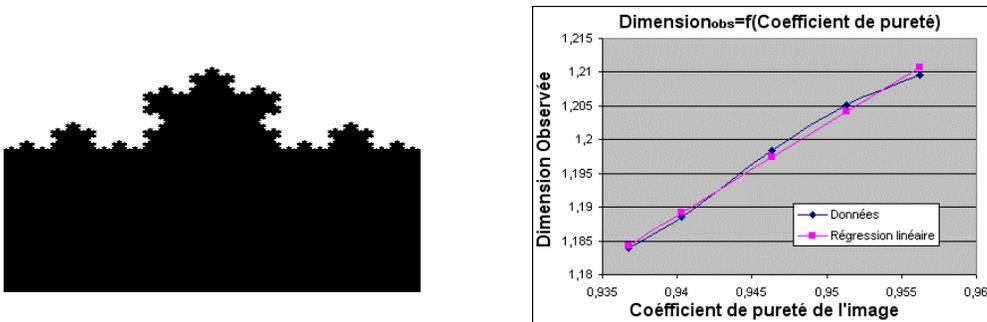


Figure 52 : Calculs des dimensions fractales et du coefficient de pureté de la courbe de Von Koch à différentes échelles d'observation. La droite de régression linéaire du type  $y=ax+b$ , nous permet d'effectuer une estimation de la dimension fractale théorique de la courbe de Von Koch à 1,27 ici.

## 4.2 Lien entre les approches floue et fractale

Cette méthode permet donc d'évaluer la dimension théorique d'une courbe à partir de l'étude du comportement de la complexité de la courbe en fonction de l'échelle d'observation. Le même calcul effectué en Annexe sur un ensemble plus diversifié de courbes fractales, nous permet d'évaluer les erreurs commises lors de l'estimation de la dimension théorique connue des fractales étudiées. La Figure 53 reprend ces différentes mesures. Cette étude nous permet de déterminer une erreur moyenne commise par notre méthode à 0,005, son écart type (dispersion) à 0,027 et avec une erreur maximale de 0,06.

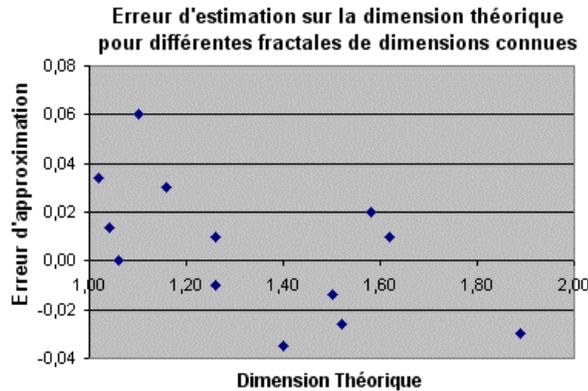


Figure 53 : Erreur d'estimation de la dimension théorique ( $D_{Th}-D_{ThEstimée}$ ) commise par notre méthode. Les cas présentés correspondent aux fractales de l'Annexe. On observe une erreur moyenne de 0,005 pour un indice de dispersion (écart type) à 0,027.

Nous venons de valider ici, si l'on peut considérer l'échantillon de courbes considérées comme représentatif, le calcul de la dimension fractale théorique pour des courbes nettes de dimension fractale connue et de quantifier l'erreur d'approximation commise. Cette erreur semble acceptable pour la plupart des applications. Nous allons donc poursuivre en utilisant ce modèle et, dans la prochaine section, nous allons nous intéresser à une image initialement bruitée.

### 4.2.3.2 Image de dimension connue initialement floue

L'interface de la Figure 54 représente une partie tronquée d'un ovoïde. La séparation entre les milieux sombre et clair paraît évidente à trouver. Elle rejoint les figures de l'espace euclidien (cercles, carrés, droites, ovoïdes...) ayant une dimension fractale proche de 1 car peu complexes.

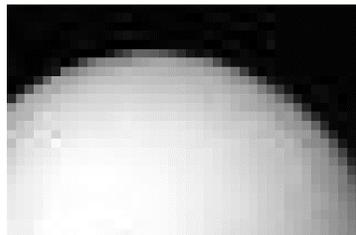


Figure 54 : Image représentant une transition entre un milieu clair et un milieu sombre.

Si maintenant on estime la dimension théorique d'un tel objet à partir de la relation (2) (Figure 55), la régression linéaire effectuée nous donne, pour dimension fractale théorique, une valeur de 1,06. La dimension obtenue, bien qu'acceptable, apparaît quand même un peu élevée. En introduisant l'indice  $T^R_{\text{normalisé}}$ , qui nous permet de prendre en compte le bruit de l'image initiale. Le nouveau graphique (Figure 56), nous permet de trouver comme dimension la valeur de 0,97 plus proche de la dimension fractale attendue (dimension théorique proche de 1).

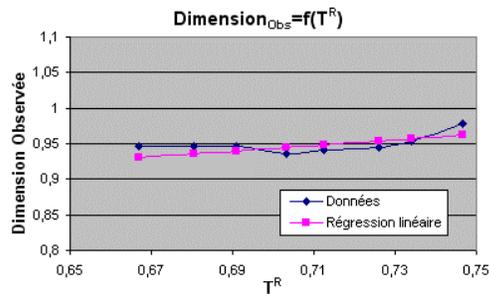


Figure 55 : Régression linéaire d'équation  $y=0,397x+0,666$  sur le nuage de points du graphique  $Dim_{\text{obs}}=f(T^R)$ . La dimension théorique peut alors être estimée par  $0,397+0,666$  soit 1,063.

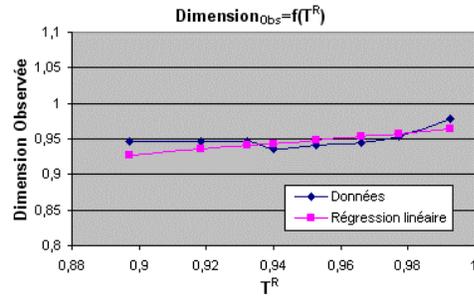
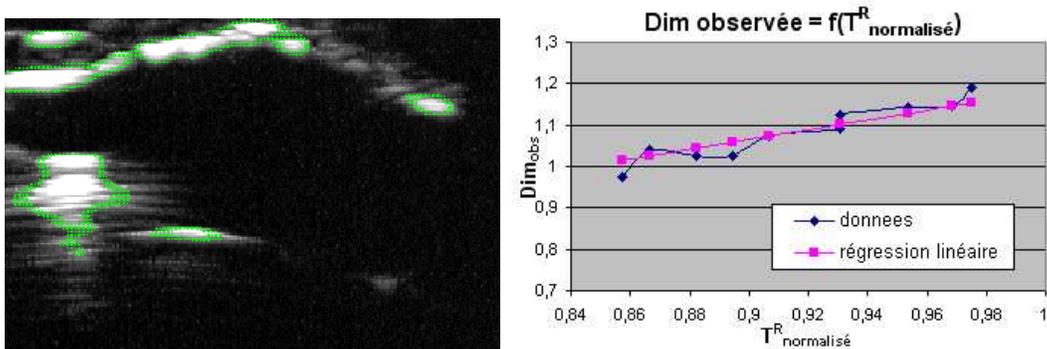


Figure 56 : Régression linéaire d'équation  $y=0,384x+0,583$  sur le nuage de points du graphique  $Dim_{\text{obs}}=f(T^R_{\text{Normalisé}})$ . La dimension théorique peut alors être estimée par  $0,384+0,586$  soit 0,97

Nous venons, sur quelques exemples, de valider notre proposition sur des courbes de dimension connue pouvant être floues initialement. Reste à voir maintenant l'application d'une telle approche sur une image ultrasonore.

#### 4.2.3.3 Image initialement floue de dimension fractale inconnue

Contrairement aux images précédentes, nous ne connaissons pas, *a priori*, la dimension théorique des interfaces présentes dans ces images. Cependant, nous retrouvons graphiquement la relation entre le taux de flou de l'image et la dimension fractale de l'interface étudiée en fonction de R (Figure 57).



représentée en vert sur l'image de gauche. La dimension estimée est de 1,18.

### 4.3 Segmentation multi milieux

La dimension fractale théorique trouvée est de 1,18. Cette valeur, bien que non démontrable en condition réelle semble avoir un ordre de grandeur tout à fait cohérent avec la complexité de la présente transition, selon la perception humaine que l'on peut en avoir.

#### 4.2.4 Conclusion

Le lien existant entre le calcul du taux de flou de l'image et la complexité des interfaces mis en évidence, nous venons de voir comment calculer la dimension fractale d'une interface à partir d'une image bruitée ou non. Bien évidemment, ne pouvant certifier la véracité d'un résultat sans connaissance *a priori* de celui-ci, une phase de validation de la méthode sur de nombreuses images de dimensions théoriques connues (synthétiques ou non) a dû être réalisée. De plus, connaître la complexité d'une interface réelle à partir d'une image bruitée apporte à l'expert une donnée quantifiée supplémentaire dans l'élaboration de son diagnostic.

La prochaine étape dans l'aide au diagnostic correspond à la proposition d'une segmentation de l'image en régions (milieux et interfaces).

### 4.3 Segmentation multi milieux

La méthode développée jusqu'ici nous permet de quantifier la complexité des interfaces entre deux milieux composant l'image sans pour autant placer, de façon exacte, la frontière entre eux. De plus, bien que notre approche ne soit pas une méthode de segmentation à proprement dit, les résultats obtenus laissent penser à une utilisation dans le cadre de la segmentation, une aide, voire une alternative, aux mauvais résultats engendrés par l'application des méthodes de segmentation traditionnelles pour certaines images. Ces approches, trop restrictives, cherchent à tracer une frontière là où il est difficile d'en distinguer une. Dans cette section, l'apport de la méthode à la segmentation est étudié.

#### 4.3.1 Détermination du nombre de milieux constituant l'image

Jusqu'à présent, n'ont été traitées que des images, synthétiques ou réelles, constituées de deux milieux et d'une transition. Le cas général est beaucoup plus complexe et pose comme premier verrou la détermination du nombre de milieux constituant l'image. Dans cet objectif, deux méthodes, ayant pour support l'histogramme des niveaux de gris de l'image, ont été implémentées : une méthode de seuillage basée sur le calcul de gradients et l'utilisation d'un algorithme génétique.

### 4.3.1.1 Recherche des modes de l'histogramme

Une méthode classique d'analyse d'histogramme consiste à étudier les dérivées (première et seconde) du signal. Prenons l'exemple de l'histogramme des niveaux de gris suivant (Figure 58) :

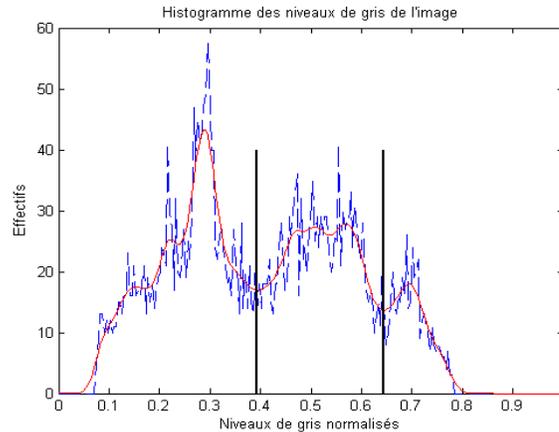


Figure 58 : Exemple d'histogramme des niveaux de gris. La courbe rouge correspond au lissage de l'histogramme par application d'une convolution (filtre de type moyenneur).

Afin d'en faciliter l'analyse, nous avons choisi d'effectuer une convolution du signal avec un filtre moyenneur. La courbe lissée ainsi obtenue (la courbe rouge) permet de limiter la recherche des optima en évitant, tant que possible, les extrema locaux. Les dérivées première et seconde, représentées sur la Figure 59, nous indiquent le nombre d'optima et leur nature (minimum ou maximum). De plus, via l'utilisation d'une valeur de seuil sur les amplitudes du gradient, nous pouvons limiter le nombre de milieux recherchés aux milieux significatifs. La difficulté de l'approche réside alors dans le choix du filtre et de la valeur du seuil.

Ainsi, les segments verticaux bleus de la Figure 58 et noirs de la Figure 59 représentent les délimitations des divers milieux présents au sein de l'image. Ce résultat a été obtenu en imposant la présence de trois milieux uniquement. Toutefois, sans connaissance *a priori* du nombre de milieux, nous pourrions trouver sur cet exemple précis 6 milieux délimités par les traits rouges et bleus verticaux sur les courbes de dérivées (seuil ajusté dynamiquement de façon à ne retenir que les 6 milieux les plus importants).

### 4.3 Segmentation multi milieux

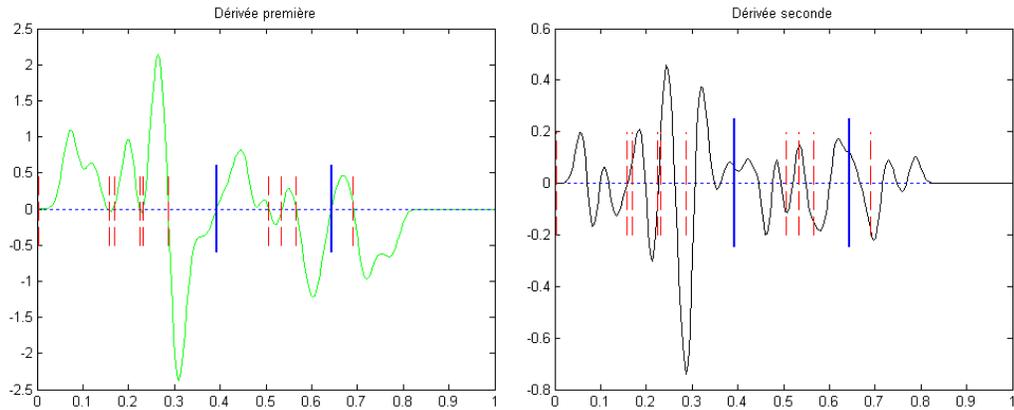


Figure 59 : Dérivées première et seconde de la courbe lissée Figure 58 avec indication de segmentation.

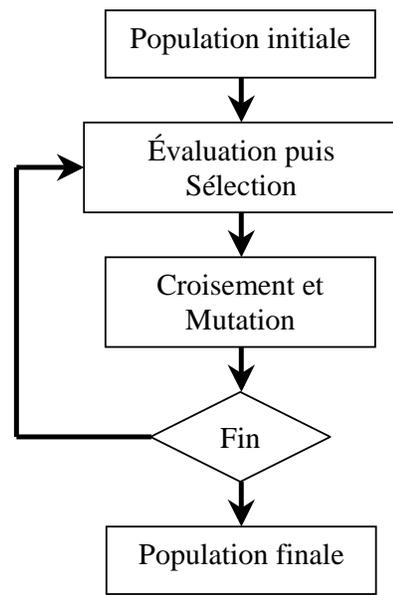
#### 4.3.1.2 Décomposition à base de gaussiennes

Cette approche est basée sur l'hypothèse que chacun des milieux constituant l'image a une distribution de ses niveaux de gris représentée par une gaussienne. La recherche des milieux revient alors à effectuer une décomposition en gaussiennes, de l'histogramme des niveaux de gris de l'image. Il existe de nombreuses méthodes pour résoudre ce problème. Nous pouvons citer la méthode des moments, du maximum de vraisemblance ou encore les méthodes d'estimation stochastiques. Pour notre étude, nous avons opté pour l'utilisation des algorithmes génétiques, certes plus longue en temps de calcul mais globalement plus facile à implémenter. Cela reste suffisant pour nous permettre de valider l'approche.

Nous rappelons ici rapidement le principe des algorithmes évolutionnaires et plus particulièrement des algorithmes génétiques. Puis nous précisons les choix réalisés dans le cadre de l'application.

Les algorithmes génétiques font partie de la famille des heuristiques permettant d'approcher une solution optimale à un problème même lorsque sa résolution analytique n'est pas envisageable. Ils reprennent la théorie de l'évolution de Darwin et l'appliquent aux systèmes informatiques. On doit l'utilisation de tels procédés pour la résolution de problèmes à John Holland et son équipe [Holland, 1975].

De façon similaire à l'évolution en science de la vie, la population initiale utilisée dans le programme informatique correspond à un ensemble d'individus de génotypes (ensemble des gènes) différents.



### Mise en œuvre théorique et pratique

Vient alors la phase d'évaluation pendant laquelle chaque individu de la population va être évalué puis éventuellement classé par rapport aux autres en fonction de son adaptation à l'environnement.

Dans le domaine informatique, une fonction coût définie au préalable nous permettra de quantifier l'adéquation entre le problème posé et l'individu comme solution.

La phase suivante correspond à la sélection des individus les mieux adaptés pour former une population intermédiaire apte à la reproduction. La littérature offre un grand nombre de possibilités parmi lesquelles on distingue : une sélection dite « uniforme » (chacun des  $n$  individus a la même probabilité  $1/n$  d'être choisi) ; une sélection par « rang » (individus les mieux classés) ; une sélection par « tournoi » : (on prend au hasard au moins deux individus ; pour chacun, on détermine la probabilité d'être tiré en comparant leurs valeurs d'adaptation et on effectue un tirage) ; une sélection dite « steady-state » (tirage aléatoirement dans un ensemble restreint aux individus les plus adaptés) ; une sélection par « roue de la fortune » (chaque individu est représenté sur un disque par une portion de camembert proportionnelle à son degré d'adaptation. Le choix des individus s'effectue ensuite de façon uniforme sur cette roue).

Une fois les individus destinés à la reproduction choisis, interviennent les opérations de reproduction. Il existe deux types de transformations génétiques : les « croisements » (échange mutuel de gènes) et les « mutations » (modification d'au moins un gène particulier chez un individu).

Mis à part pour le type de sélection « steady-state » où le principe est de ne changer que quelques individus entre deux populations successives (les plus faibles), les autres types de sélections visent généralement à remplacer 50% de la population. Entre deux populations successives, on va donc retrouver des individus parents, de la première génération, et des individus enfants, issus de la recombinaison entre individus parents et/ou des opérations de mutation. En reproduisant ainsi un grand nombre de fois le processus, on finit par avoir des individus très spécialisés répondant de mieux en mieux aux critères de la fonction d'évaluation.

#### Choix pour l'application :

- Modélisation des individus ("chromosomes"). Chaque individu regroupe l'ensemble des paramètres ( $A$  : amplitude,  $\mu$  : espérance,  $\sigma$  : écart type) des Gaussiennes correspondant à une solution donnée. Pour faire l'analogie avec la génétique, chacun de ces paramètres peut être vu comme un gène. Pour un nombre " $k$ " connu de milieux, les chromosomes sont tous de longueur fixe " $3k$ " (Figure 60 et Figure 62).

### 4.3 Segmentation multi milieux

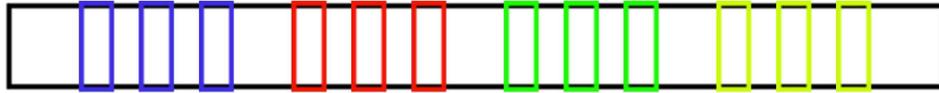


Figure 60 : Modélisation d'un chromosome de longueur connue  $3k$  (avec  $k=4$  ici)

Remarque :

Dans le cas d'un nombre de milieux inconnu, on peut choisir de ne pas fixer la taille des chromosomes. Les chromosomes ont alors une taille comprise dans un intervalle  $[k_{\min}, k_{\max}]$  fixé préalablement. Bien évidemment, plus le mélange présentera de gaussiennes, plus on aura de chance d'épouser l'histogramme des niveaux de gris (le cas extrême se résumant à un histogramme de niveaux de gris réduit en un ensemble de gaussiennes de dispersion nulle). Il sera donc nécessaire de modifier la fonction coût de façon à limiter le nombre de gaussiennes composant le mélange où pénaliser les gaussiennes à faible dispersion. Les phases de croisement et de mutation agissent de façon similaire que l'on connaisse ou non le nombre de milieux présents initialement. La Figure 61 illustre l'opération de croisement.

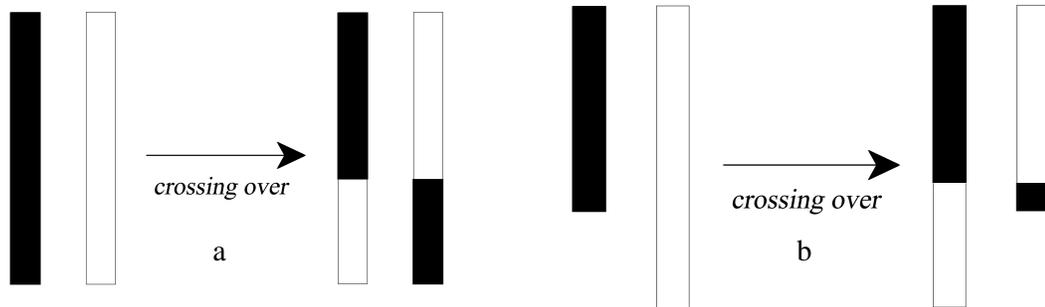


Figure 61 : Exemple de « crossing-over », recombinaison, entre deux chromosomes de tailles identiques (même nombre de paramètres) pour le cas (a) et entre deux chromosomes de tailles différentes (b).

- Choix de la fonction coût (c'est-à-dire de la fonction d'adaptation). Pour l'approximation de l'histogramme des niveaux de gris de l'image, il y a principalement deux alternatives : on peut estimer l'écart entre l'histogramme et la courbe résultant, soit de l'addition des différentes Gaussiennes, soit de leur superposition. La dernière solution permet de prendre en considération le fait qu'un pixel de l'image puisse appartenir à plusieurs milieux à la fois (base de la logique floue).

Les fonctions coût peuvent alors s'écrire de la façon suivante :

$$\text{Cas de l'addition : } f_{\text{cout}} = \sum_{i=1}^{256} \left( h(i) - \sum_{k=1}^K \frac{A_k}{\sigma_k \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{i - \mu_k}{\sigma_k}\right)^2\right) \right)^2$$

$$\text{Cas de la superposition : } f_{\text{cout}} = \sum_{i=1}^{256} \left( h(i) - \max_k \left[ \frac{A_k}{\sigma_k \sqrt{2\pi}} \exp \left( -\frac{1}{2} \left( \frac{i - \mu_k}{\sigma_k} \right)^2 \right) \right] \right)^2$$

Avec  $h(i)$  le nombre d'individus ayant un niveau de gris égal à  $i$  donné par l'histogramme de l'image et  $k$  désignant la  $k^{\text{ième}}$  gaussienne sur  $K$  possibles.

- Choix des paramètres liés à l'algorithme génétique :
  - \_ Nombre de chromosomes : proportionnel au nombre de milieux.
  - \_ Probabilité de « crossing-over » : 0,5
  - \_ Probabilité de mutation : 0,01
  - \_ Mode de sélection : par tournoi (en prenant les individus 2 par 2).
  
- Arrêt de l'algorithme : Le principe des algorithmes génétiques étant de réaliser un grand nombre de générations, il est de coutume d'arrêter le processus lorsque la solution proposée est « acceptable » (fonction coût inférieur à un seuil fixé par l'utilisateur par exemple). De plus, une uniformisation de la population s'opérant au fur et à mesure des itérations, le gain probable entre deux populations successives diminue rapidement lors des premières itérations.

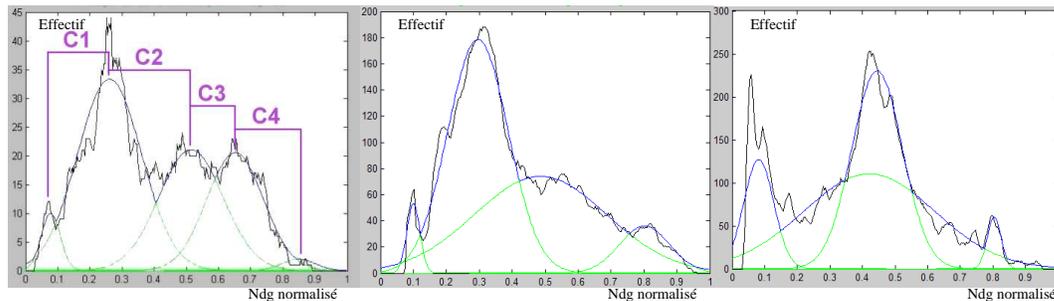


Figure 62 : Exemple de mélanges à 4 gaussiennes obtenus pour 3 histogrammes de niveaux de gris différents. Les couples  $C_1$ ,  $C_2$ ,  $C_3$  et  $C_4$  de la figure de gauche correspondent aux couples de milieux utilisés pour la recherche de zones de transitions (section 4.3.2).

### 4.3.2 Segmentation par couples de milieux

Une fois les divers milieux identifiés, nous allons maintenant nous intéresser aux diverses interfaces qui les séparent. De façon intuitive, la première approche consiste à prendre les milieux deux à deux et à appliquer, à chacun des couples ainsi constitués, l'approche développée jusqu'alors entre deux milieux. En fait, la définition des zones de transitions nécessite de limiter l'étude à certains couples uniquement.

Prenons, pour illustrer la remarque, le cas d'une image composée de trois milieux telle que celle de la Figure 63A. Cette image est composée de 3 milieux uniformes dont les niveaux de gris ( $N_1=254$  pour la couleur blanche,  $N_2=127$  pour le gris, et  $N_3=0$  pour le noir) vérifient la relation :

### 4.3 Segmentation multi milieux

$$N_1 > N_2 > N_3 \quad \text{avec} \quad N_2 = \frac{(N_1 + N_3)}{2}$$

Commençons par rechercher l'interface séparant les milieux de niveaux de gris extrêmes (blanc et noir). Le calcul des coefficients de pureté nous amène à calculer les degrés d'appartenance de chaque pixel de l'image aux deux milieux de références symbolisés par leurs niveaux de gris  $N_1$  et  $N_3$ . En se plaçant dans le cas d'un voisinage représenté sous la forme d'un disque de rayon  $r$  et pour une échelle d'observation  $R$  précisée par l'utilisateur, le degré d'appartenance d'un point intérieur au milieu gris vis-à-vis du milieu de référence blanc peut alors s'exprimer sous la forme (section 3.3.1.2) :

$$m_{N_1}(P_{N_2}, R) = \frac{\int_{r=1}^R N_2 \pi r^2 dr}{\int_{r=1}^R N_1 \pi r^2 dr} = \frac{N_2}{N_1} = \frac{1}{2} + \frac{N_3}{2N_1} = \frac{1}{2}$$

Avec  $m_{N_1}(P_{N_2}, R)$  le degré d'appartenance d'un point  $P$ , intérieur au milieu  $N_2$  pour l'échelle d'observation  $R$ , au milieu symbolisé par le niveau de gris  $N_1$ .

Les points  $P_{N_2}$ , ainsi considérés, se verront donc affecter un coefficient de pureté minimum ( $c(P_{N_2}, R) = \frac{1}{2}$ ) les faisant ainsi appartenir à la zone de transition séparant les deux milieux définis par  $N_1$  et  $N_3$ , ce qui n'aurait pas de sens pour notre problème. Le cas B1 de la Figure 63 illustre ce phénomène.

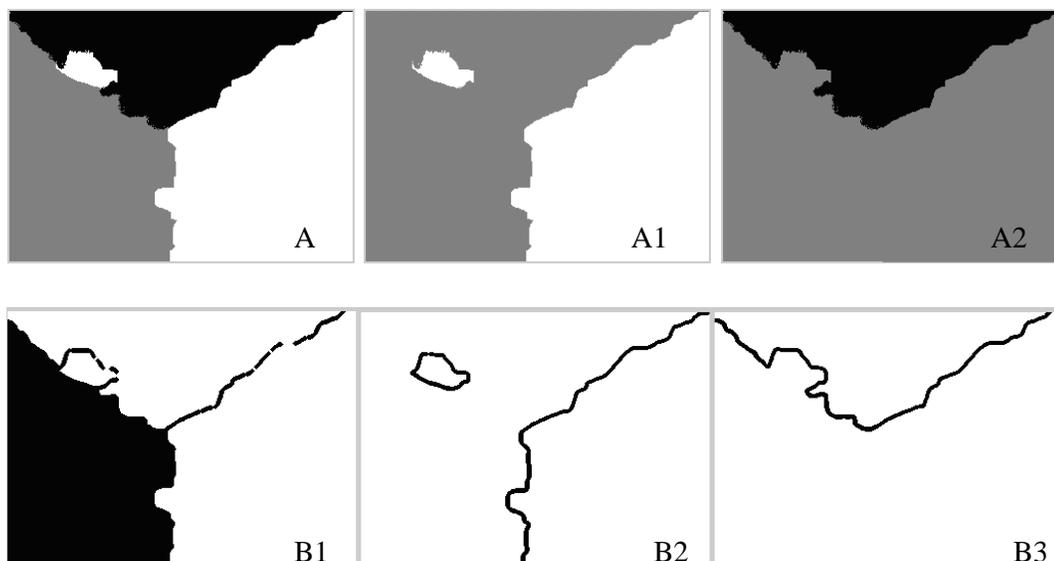


Figure 63 : Exemple de segmentation pour une image à trois milieux.

A : Image initiale à trois milieux : ndg=0, ndg=127 et ndg=254

A1 : Image A modifiée de façon à extraire les transitions entre les milieux blanc et gris de l'image initiale plus une partie des transitions entre les milieux blanc et noir.

### Mise en œuvre théorique et pratique

A2 : Image A modifiée de façon à extraire les transitions entre les milieux blanc et gris de l'image initiale plus une partie des transitions entre les milieux blanc et noir.

B1 : Segmentation obtenue entre les milieux noir et blanc ( $R=4$  et  $k=0,07$ )

B2 : Segmentation obtenue entre les milieux blanc et gris de l'image A1 ( $R=4$  et  $k=0,07$ )

B3 : Segmentation obtenue entre les milieux noir et gris de l'image A2 ( $R=4$  et  $k=0,07$ )

La solution envisagée consiste alors à ne pas traiter l'ensemble des couples possibles. Le principe est de travailler sur des ensembles de couples qui ont des moyennes en niveau de gris adjacentes (couples Noir/Gris et Gris/Blanc de la Figure 63 et couples  $C_1$ ,  $C_2$ ,  $C_3$  et  $C_4$  de la Figure 62).

Pour un couple sélectionné donné, de niveau de gris moyen  $N_i$  et  $N_j$  ( $N_i < N_j$ ), on transformera l'image de la façon suivante avant d'effectuer la recherche des transitions :

$\forall P \in \text{Image}$ , si  $P < N_i$  alors  $P = N_i$  et si  $P > N_j$  alors  $P = N_j$ .

Les pixels de l'image sont alors tous compris dans l'intervalle  $[N_i, N_j]$  et la recherche de la zone de transition entre ces deux milieux peut commencer.

Les résultats B2 et B3 de la Figure 63 sont obtenus en appliquant la méthode sur les couples de milieux « blanc/gris » et « gris/noir » respectivement sur les images A1 et A2 de la même figure. Ils permettent d'extraire les transitions de la zone blanche et de la zone noire avec les autres milieux. La superposition de ces deux résultats nous donne la carte de toutes les transitions extraites de l'image A. Pour obtenir le contour de la zone initialement grise, il suffit de superposer les contours des résultats B2 et B3, soit la carte des contours dans notre cas, et y soustraire les contours en commun entre ces deux résultats.

Passons maintenant à l'étude plus complexe d'une image ultrasonore. Sur les milieux extraits via l'algorithme génétique, comme illustré à la Figure 62, il suffit donc d'appliquer le procédé présenté au chapitre précédent en prenant les milieux 2 à 2 dans l'ordre croissant des moyennes des Gaussiennes d'approximation. La Figure 64 et la Figure 65 présentent deux exemples d'images sur lesquelles l'application de l'algorithme génétique nous précise la présence de 4 milieux (3 nuances de gris et un milieu globalement noir). On retrouve alors les 3 transitions obtenues en prenant en considération les milieux 2 à 2.

### 4.3 Segmentation multi milieux

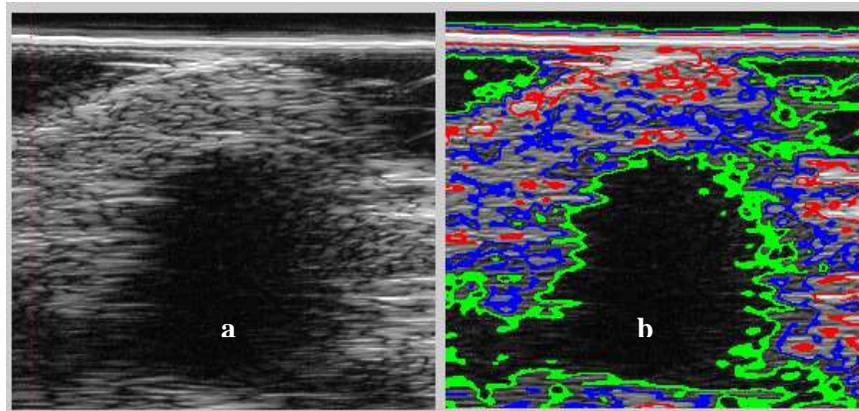


Figure 64 : Exemple de segmentations obtenues (b) sur une image ultrasonore (a) pour une échelle d'observation  $R=10$ .

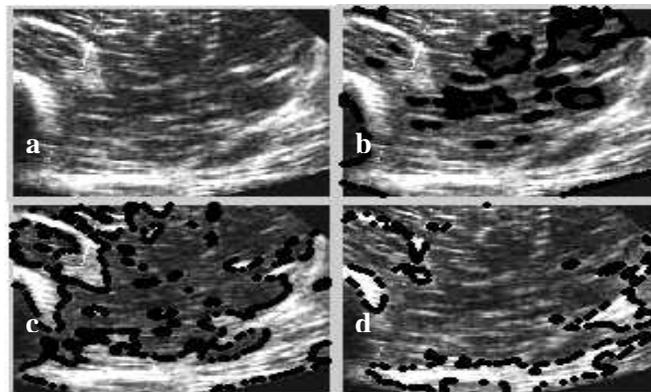


Figure 65 : (a) Image ultrasonore comportant 4 milieux  $A_1...A_4$ , du plus foncé au plus clair ; (b) la séparation entre les milieux  $A_1$  et  $A_2$  ; (c) la séparation entre les milieux  $A_2$  et  $A_3$  ; (d) la séparation entre  $A_3$  et  $A_4$ . Les transitions sont obtenues en prenant  $R=10$ .

Bien évidemment, la qualité de la segmentation (et donc la présence des détails) dépend fortement de l'échelle d'observation  $R$  choisie. Ce paramètre peut donc être paramétré en fonction de la qualité souhaitée. Une valeur trop faible de ce paramètre ne permettra pas une homogénéisation suffisante des divers milieux et rendra l'identification des diverses structures difficile. *A contrario*, une valeur trop élevée de  $R$ , entraînera un lissage trop prononcé des structures et une perte de détails trop importante.

Ces segmentations, bien que grossières, nous permettent d'avoir une idée globale de la structure générale. L'image initiale se trouve alors décomposée en milieux et transitions. Dans le paragraphe suivant, nous cherchons à quantifier la qualité de la partition proposée via notamment une comparaison avec d'autres méthodes usuelles de segmentation.

#### 4.3.3 Évaluation de la segmentation

Trouver un critère universel nous permettant de comparer deux résultats de segmentation entre eux reste difficile encore aujourd'hui. Il existe en effet

une multitude d'indices pour l'évaluation d'une segmentation. On peut citer le PSNR (Peak Signal to Noise Ratio) ou encore le critère de Vinet [Vinet, 1991]. Toutefois, ces indices sont bien souvent dépendants du type des images analysées. Leur non efficacité pour le traitement des images ultrasonores renforce l'idée du besoin d'une approche psychovisuelle à mettre en place dans le milieu médical.

Dans le but d'apporter une évaluation la plus correcte possible, une comparaison avec divers résultats obtenus via l'utilisation de méthodes classiques (telles que celles basées sur les gradients, les contours actifs ou encore la croissance de région) est nécessaire.

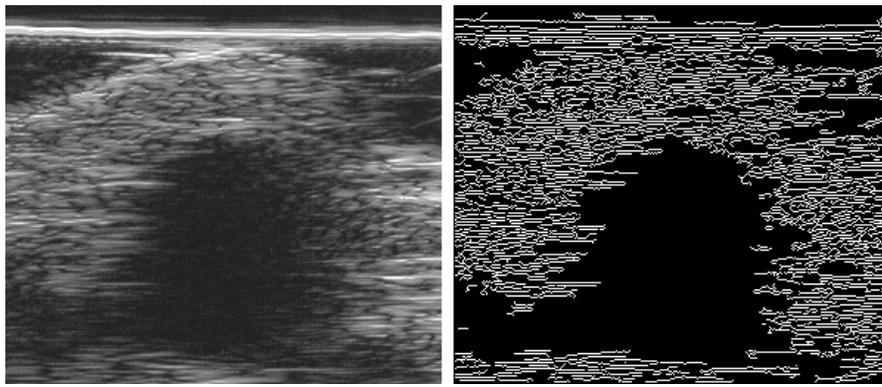


Figure 66 : Résultat obtenu par une méthode de segmentation basée sur le détecteur de contours de Canny (gradient). Ce résultat est obtenu en appliquant deux fois le filtre sur l'image initiale avec des paramètres de sensibilité (seuils) différents, respectivement 0,1 et 0,3, pour une déviation standard du filtre Gaussien à 0,1.

Même en essayant de trouver la valeur du paramètre de sensibilité optimale, les méthodes basées sur une étude du gradient (Figure 66) ne donnent pas de segmentations. Les contours actifs, nécessitant autant d'initialisations que de contours à détecter et une connaissance *a priori* de l'image à traiter n'ont pas été implémentés car trop contraignants. Ils sont très efficaces dans la recherche d'un contour, d'un organe particulier, mais ne permettent pas d'extraire l'ensemble, utilisable par un expert du domaine, des contours d'une image donnée sans intervention de l'utilisateur. Reste donc à comparer les résultats issus de l'application d'un algorithme de croissance de régions et de notre méthode.

L'algorithme utilisé pour la croissance de régions proposée ici le suivant.

De façon similaire à ce qui a déjà été présenté à la section 3.4.2, nous commençons par calculer en chaque point de l'image, un vecteur d'attributs. Ce vecteur correspond ici à un vecteur regroupant les moments d'ordre 1 à 4 calculés sur un voisinage de taille défini initialement (voisinage carré de 9 pixels de côté par exemple) et centré sur le pixel étudié.

### 4.3 Segmentation multi milieux

L'étape suivante consiste à initialiser l'algorithme de recherche de région en spécifiant leurs points de départ, communément appelés « germes ». Un maillage de germes (une grille) est alors superposé sur l'ensemble de l'image. On choisit généralement un maillage très fin de façon à conserver au moins un germe dans chacune des structures, objets, présents dans l'image initiale. Nous avons donc initialement autant de régions que de germes.

Vient ensuite la phase d'affectation des autres pixels aux différentes régions. Tant qu'il reste un pixel non affecté à une région, on itère le processus suivant : on recherche sur toute l'image le pixel le plus apte à l'affectation, au sens distance entre son vecteur d'attributs et ceux des différentes régions (moindres carrés) ainsi que la distance entre le pixel et les possibles régions candidates (distance euclidienne). Une fois déterminé, on affecte ce pixel à la région correspondante et le vecteur d'attribut de la région est mis à jour (moyenne des vecteurs d'attributs des différents pixels appartenant à cette région).

Tous les pixels de l'image étant affectés aux différentes régions, une phase de fusion des différentes régions est appliquée. Le processus itératif pour arriver à un tel résultat consiste à détecter les deux régions candidates à la fusion (au sens distance entre leurs vecteurs d'attributs), puis les fusionner et remettre à jour le vecteur d'attribut de la nouvelle région. A chaque nouvelle itération, on décrémente le nombre de régions de 1. L'algorithme s'arrête alors lorsque le nombre de régions souhaité est atteint (par exemple 4 pour le cas de la Figure 67).

La Figure 67 reprend les résultats obtenus à la fois par cette méthode de croissance de régions et la méthode proposée dans ce manuscrit afin de pouvoir les comparer.

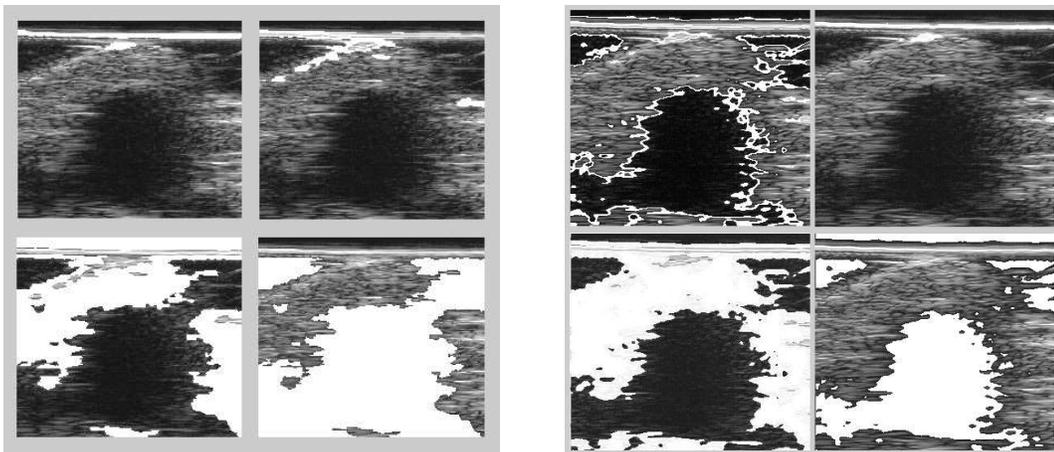


Figure 67 : Résultats obtenus par une méthode basée sur la croissance de régions (à gauche) et notre méthode (à droite). Chaque image représente une des régions mises en évidence par la méthode.

Étant donnée la difficulté d'évaluer de façon objective les résultats sans indicateur efficace, nous avons utilisé comme référence la segmentation

proposée par le corps médical. La synthèse des propositions formulées par les experts, présentée sur la Figure 68, permet de comparer les différentes approches. Une précision peut être apportée quant au protocole expérimental utilisé. Plutôt que de présenter différents résultats de segmentation aux divers experts et leur demander d'effectuer une classification, le protocole envisagé est basé, pour une image donnée, sur une segmentation réalisée par chaque spécialiste. Celui-ci fournit ainsi une partition de l'image, sans aucune concertation ou influence extérieure.

En remarque, nous pouvons souligner le fait que les différences d'analyse entre les experts font que la vérité terrain reste difficile à évaluer de par la disparité des résultats. Pour pallier cela, il serait judicieux de réaliser une étude statistique sur les représentations.

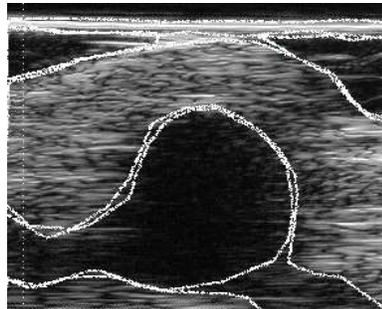
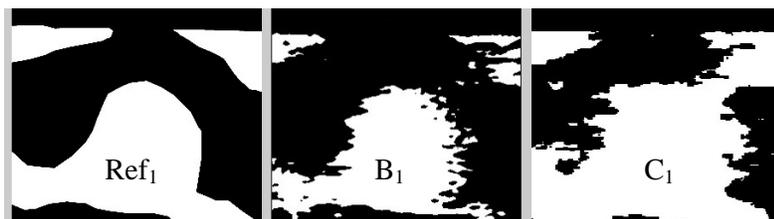


Figure 68 : Segmentation réalisée par un expert sur l'image ultrasonore de la Figure 64.a.

Globalement, notre méthode semble plus adaptée au problème posé que les autres méthodes envisagées. En effet, la variation de l'échelle d'observation offre la possibilité d'atteindre divers niveaux de détails du contour attendu. Cela permet notamment à l'expert de faire abstraction de la structure interne des tissus pour appréhender la structure globale de l'environnement. Par exemple, les régions de la Figure 67, extraites par notre méthode, semblent correspondre davantage aux attentes des experts. Dans le but de comparer ces résultats de manière objective, un calcul basé sur la similarité entre les résultats obtenus (Figure 69) et « la vérité terrain », proposée par les spécialistes ( $Ref_i$ ), peut être effectué.



### 4.3 Segmentation multi milieux



Figure 69 : Exemple de régions extraites :

$Ref_i$  : régions proposées par les experts

$B_i$  : régions extraites par notre méthode

$C_i$  : régions extraites via une méthode de croissance de région

On va alors chercher à quantifier la valeur des résultats obtenus par les méthodes informatiques. Pour cela, nous définissons : la région à tester ( $Reg$ ) et celle de référence ( $Ref_i$ ). On distingue alors deux indices, très largement utilisés en recherche d'information pour quantifier la qualité d'un résultat par rapport à une référence : le rappel et la précision.

- la précision correspond à la proportion d'éléments bien placés (appartenant aussi à la référence) par rapport à l'ensemble des éléments retournés :

$$Précision = card(Reg \cap Ref_i) / card(Reg)$$

Pour le cas extrême d'une région composée uniquement d'un seul élément appartenant lui aussi à la région de référence on trouvera une précision de 1.

- le rappel correspond au nombre d'éléments trouvés par rapport à l'ensemble des éléments de la référence :

$$Rappel = card(Reg \cap Ref_i) / card(Ref_i)$$

Le Tableau 4.1 et le Tableau 4.2 reprennent ces calculs d'indices pour comparer les régions extraites à la Figure 69. Notre méthode offre globalement un pourcentage de chevauchement plus important entre les régions extraites de la segmentation et la référence. De plus, on voit qu'en moyenne notre méthode fournit des régions incluses en presque totalité dans le milieu recherché (sans trop de débordements).

Tableau 4.1 : Indices de recouvrement calculés sur la partie haute de la Figure 69

	Milieu de référence $Ref_1$		
	Précision (P)	Rappel (R)	F-mesure
Notre méthode ( $B_1$ )	0,90	0,75	82,24
Méthode régions ( $C_1$ )	0,66	0,93	77,44

Tableau 4.2 : Indices de recouvrement calculés sur la partie basse de la Figure 69

	Milieu de référence $Ref_2$		
	Précision (P)	Rappel (R)	F-mesure
Notre méthode ( $B_2$ )	0,81	0,84	82,50
Méthode régions	0,78	0,60	67,94

(C <sub>2</sub> )			
-------------------	--	--	--

Les mesures de rappel et précision sont en fait utilisées de manière conjointe. En effet, une bonne estimation de la région de référence est déterminée par sa faculté à retrouver tous les éléments de la référence tout en ne retrouvant que ces éléments. La qualité se mesure donc grâce au couple précision/rappel. Apparaît de plus dans ces tableaux une mesure proposée dans [Van Rijsbergen, 1979], la « *F-mesure* », définie comme suit :

$$F = 2 * (\text{Précision} * \text{Rappel}) / (\text{Précision} + \text{Rappel})$$

Cet indice combine la précision et le rappel d'un résultat en une mesure unique d'efficacité globale. Il renforce l'idée que notre méthode reste plus adaptée au problème posé. On pourrait de plus ajouter à cette phase d'évaluation une comparaison du nombre de paramètres à régler nécessaires pour l'obtention du résultat. Dans le cas des comparaisons effectuées à la Figure 69, notre algorithme ne nécessite le réglage que de deux paramètres (R et k) contre un nombre beaucoup plus élevé pour l'algorithme à croissance de régions (un grand nombre de germes à l'initialisation, le critère d'homogénéité...).

#### **4.3.4 Prétraitement d'une compression adaptée au contenu**

#### **4.4 Éléments de Compression**

Les moyens technologiques actuels, tant en capacité de stockage qu'en bande passante pour le transfert de données, laissent penser que la nécessité de compresser les données à traiter n'est plus aussi importante. Cependant, la compression de données reste un problème de taille dans de nombreuses applications. Citons comme exemples les visioconférences, le stockage d'exams médicaux, la téléphonie, la télévision numérique, la sauvegarde de données sur supports amovibles faciles d'utilisation, la télémédecine...

Le coût des technologies (liaisons satellites, périphériques de stockage) mais aussi quelquefois leurs limites, renforcent l'idée d'un besoin de compression. Citons par exemple le cas de la télé opération itinérante ; la bande passante n'offre pas un débit suffisant à l'examen temps réel distant via le transfert d'images peu, voire pas du tout, compressées (utilisation d'algorithmes sans pertes). Si pour l'examen à distance de l'image échographique, dans l'étape de localisation de la sonde une qualité moindre de l'image est acceptable, une étape de compression avec perte peut être envisagée. Une image grossière est suffisante pour assurer une réactivité temps réelle. Bien sûr, pour un diagnostic, la qualité de l'image transmise doit être maximale. (une compression avec perte n'est pas envisageable).

### 4.4.1 État actuel de la compression de données

L'objectif de toute méthode de compression de données réside dans la limitation du nombre de bits nécessaires à l'expression des données par, bien souvent, suppression de la redondance présente dans les données. Cette redondance peut être :

- spatiale : motifs qui se répètent au sein d'une même image ou encore une succession de caractères identiques dans un fichier texte ;
- par couche spectrale : motifs qui se répètent dans les couches rouge, verte et bleue d'une image RGB ;
- temporelle : objet qui est présent dans plusieurs images successives d'une séquence vidéo.

Nous limiterons ici l'analyse à la compression d'images fixes. La compression de flux vidéo ne sera pas présentée ici. Il existe de nombreux travaux sur la compression de données [Delgorge, 2005] [Barlaud et Labit, 2002]. Il est d'usage de séparer les méthodes de compression d'images en fonction d'une perte dans l'image reconstruite. Introduite par Shannon, la notion d'entropie permet d'estimer le volume nécessaire pour transmettre l'information sans perte [Shannon, 1948].

Introduite par C.Shannon [Shannon, 1948], l'entropie  $H$  d'une source  $S$ , caractérisée par son alphabet  $\{s_1, s_2 \dots s_n\}$  et les probabilités d'occurrence associées  $\{p(s_1), p(s_2) \dots p(s_n)\}$ , correspond à la quantité moyenne d'information des symboles de la source. Elle est exprimée en bits et donnée par l'expression :

$$H(S) = -\sum_{i=1}^n p(s_i) \times \log_2(p(s_i))$$

On la trouve souvent exprimée sous la forme  $H(S) = \sum_{i=1}^n H_{s_i} \times p(s_i)$  avec  $H_{s_i} = -\log_2(p(s_i))$ , la quantité d'information qu'apporte l'apparition du symbole  $s_i$ . Ainsi, plus la probabilité d'apparition d'un symbole ( $s_i$ ) est faible, plus l'information apportée  $H_{s_i}$  est importante.

On regroupe alors les méthodes de compression en deux catégories :

- Les approches « sans perte » (Run-Length Encoding, Huffman, Shannon-Fano, lempel-Ziv). Elles permettent, suite au cycle complet de compression puis décompression, d'obtenir finalement une image similaire en tout point à l'image initiale. Il n'y a pas dégradation [Guillois, 1996]. Cependant, le taux de compression de telles techniques reste très faible (taux limité par l'entropie du message). On y trouve des méthodes basées sur des codeurs non adaptatifs (utilisant la probabilité

d'apparition des caractères), et des codeurs adaptatifs (statistique construite dynamiquement au fur et à mesure de l'apparition des données).

- Les approches « avec perte » (utilisant des ondelettes, des IFS, les transformées de Fourier...) : Contrairement aux approches sans perte, l'image en sortie du processus correspond à l'image initiale dégradée, altérée. Cependant, ces techniques permettent des taux de compression beaucoup plus importants (nombre de bits nécessaires au codage de l'information inférieur au nombre de bits fourni par son entropie)

## 4.4.2 Compression par IFS

### 4.4.2.1 La compression fractale classique

Cette méthode vise à trouver un IFS (Iterated Function System) dont l'attracteur (l'unique point fixe) se rapproche le plus possible de l'image initiale à compresser. L'approche présentée au chapitre 3 sur l'approximation de courbes par IFS est donc appliquée ici à la modélisation d'image.

Le principe de compression est le suivant : on découpe l'image en blocs, les « range blocs », de  $2^n \times 2^n$  pixels, eux-mêmes pouvant être subdivisés en blocs de  $2^{n-1}$  pixels de côté.

Chaque bloc peut alors être codé sous la forme d'une transformation mathématique [Fisher, 1994] (fonctions de réajustement : rotation, changement d'échelle ; fonctions d'intensité : ajout de luminosité, de contraste), calculée à partir d'une autre région de l'image originale (domaine bloc) (Figure 70).



*Figure 70 : Exemples de transformations permettant de retrouver un range bloc à partir d'un domaine bloc plus grand dans l'image Lena.*

Pour un range bloc donné, trouver le point fixe exact n'est pas une opération facilement réalisable ; on se limitera donc à la recherche de l'attracteur le plus fidèle possible par minimisation de l'erreur quadratique calculée entre lui et le range bloc initial. Au final, chaque bloc  $2^n \times 2^n$  de l'image sera donc codé par la position et les dimensions du domaine bloc dans

#### 4.4 Éléments de Compression

l'image ainsi que la fonction de transformation «  $f_i$  » (d'où la compression, amplifiée par l'utilisation d'algorithme de compression tel que le codage d'Huffmann [Huffmann, 1952]). La Figure 71 présente quelques résultats de compression par IFS obtenus sur l'image « Lena ».

Nous nous retrouvons alors dans le cadre de la compression par PIFS (Partitioned Iterated Function System) :

Soit  $F_0$  un compact de l'espace métrique complet  $(H(X), d_H)$  avec  $H(X)$  l'ensemble des compacts non vides de l'espace métrique  $(X, d)$ ,  $d_H$  la distance de Hausdorff associée à  $d$ , la distance utilisée sur l'espace  $X$ .

Soit  $f_1, f_2, \dots, f_n$  un ensemble de fonctions contractantes respectivement de rapports de contractance  $k_1, k_2, \dots, k_n$  sur  $(H(X), d)$ . Dans le cadre de la compression d'image,  $n$  est égal au nombre de ranges blocs.

Alors on a :

$$F_0 \in H(X) \quad \text{et} \quad F_1 = \bigcup_{i=1}^n f_i(F_0) \quad \text{et} \quad F_N = \bigcup_{i=1}^n f_i(F_{N-1}), \quad \forall N \geq 2$$

On peut alors démontrer qu'il existe un unique compact  $F^*$  de  $(H(X), d)$  tel que :

$$\bigcup_{i=1}^n f_i(F^*) = F^* \quad \text{et} \quad \forall F_0 \in (H(X), d), \quad \lim_{N \rightarrow \infty} (F_N) = F^*$$

La reconstruction de l'image originale peut alors s'effectuer par itérations successives de l'ensemble des transformations ( $f_i$ ) sur un compact quelconque  $F_0$  :

$$F^* = \bigcup_{i=1}^n f_i \left( \dots \bigcup_{i=1}^n f_i \left( \bigcup_{i=1}^n f_i \left( \bigcup_{i=1}^n f_i (F_0) \right) \right) \right)$$

Ce phénomène est lié à la propriété de contractance des transformations (le théorème du "collage" [Barnsley, 1988] garantissant cette convergence) et à la complétude de l'ensemble des fermés bornés pour la distance de Hausdorff.



Figure 71 : Image « Lena » (a) et images obtenues via une compression fractale pour laquelle les tailles des domaines blocs carrés ont été fixées à 4 pixels (b), 8 pixels (c) et 16 pixels (d)

*de côté. PSNR respectifs de 33,03, 26,81 et 14,28 pour les images b, c et d par rapport à l'image originale*

Cette approche, bien que locale au niveau de l'image (domaine bloc) ne permet pas de prendre en considération l'information contenue dans l'image. Toutefois, de nombreuses améliorations ont été proposées. Le découpage des domaines blocs peut alors être le fruit d'un « quadtree » ; la séparation s'effectue alors selon un critère précis pouvant être un seuillage sur l'erreur quadratique entre le bloc à coder et l'attracteur de l'IFS envisagé pour le synthétiser. Dans les prochaines sections, nous allons proposer des éléments de compression adaptés au contenu de l'image à compresser.

#### **4.4.2.2 La compression envisagée**

Dans la cadre de la télé-échographie robotisée dans lequel nous nous situons pour l'application de cette étude, l'examen à distance est réalisé par l'expert en deux phases : une phase de « navigation » durant laquelle l'expert balaie l'environnement, sous plusieurs incidences, à la recherche de l'organe ; et une phase d'analyse sur l'image lorsque la coupe idéale est atteinte.

Tirant parti de la segmentation proposée en section 4.3, nous proposons de compresser différemment les divers objets (milieux et interfaces) présents dans l'image. La méthode développée par la suite, ne restituant qu'une image approximative de l'image initiale ne peut être utilisée à des fins d'analyse de l'image décompressée mais uniquement pendant la phase dite « de navigation ».

L'idée consiste alors à s'appuyer sur la dynamique du geste de l'expert pour envoyer dans un cas une image grossière, dégradée mais, fortement compressée et dans l'autre cas, une image très faiblement compressée, de bonne qualité. Lors de la phase de navigation, l'expert effectue des gestes amples et rapides nécessitant une forte réactivité du système et un taux de rafraîchissement plus élevé que pour la phase d'analyse où les déplacements sont lents, modérés voir quasi-inexistants (l'expert peut par exemple geler l'image).

Nous allons par la suite étudier la faisabilité d'une méthode de compression adaptée à la phase de navigation (image dégradée mais pouvant offrir un fort taux de compression). Lors de la phase d'analyse, des méthodes traditionnelles telles que le Jpeg2000 pour les images fixes et le Mpeg pour la vidéo pourront être envisagées.

##### **4.4.2.2.1 Principe de compression**

Nous allons nous appuyer sur la caractérisation des divers composants de l'image pour les compresser différemment. Quelques méthodes présentes dans la littérature vont être développées ici afin de répondre à cet objectif. Nous allons alors différencier l'approche « interfaces », restreinte dans un premier

temps à la notion de courbes, de l'approche « milieux » s'apparentant plus à la compression d'une texture. Le schéma de la Figure 72 reprend le principe de compression.

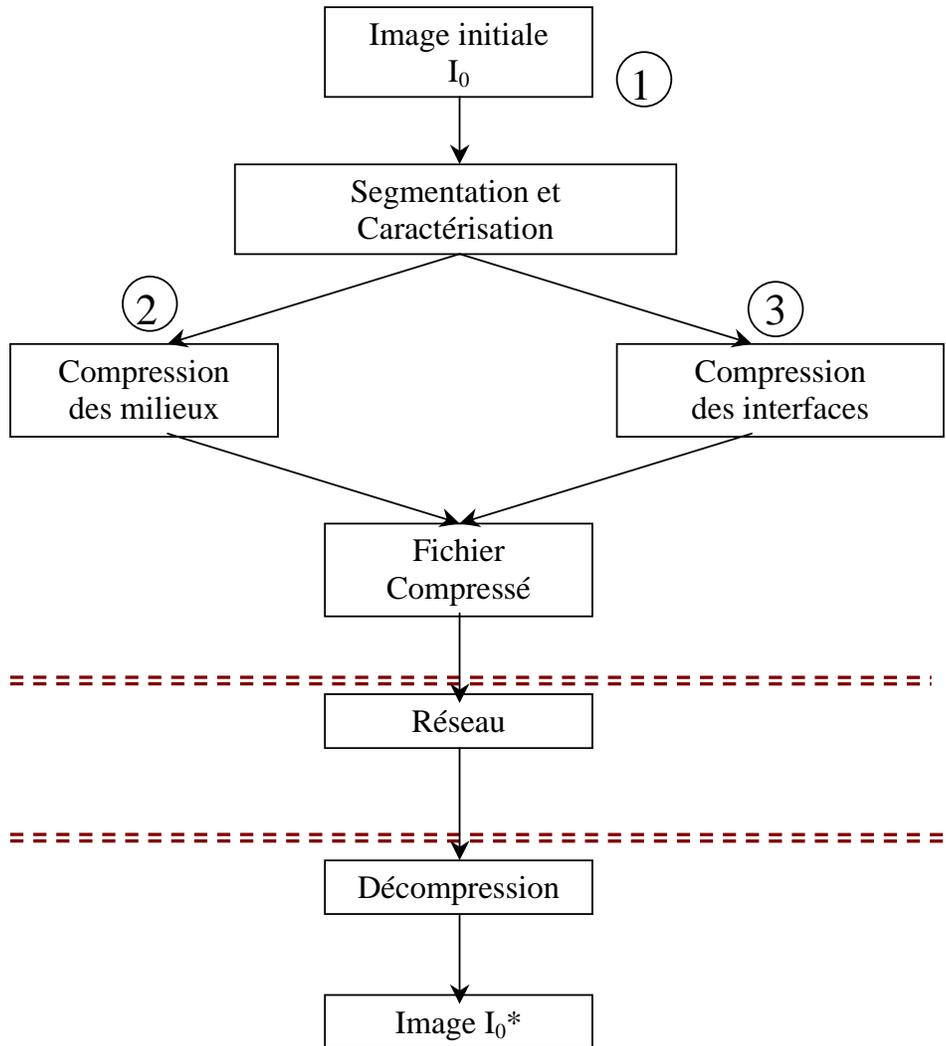


Figure 72 : Schéma de compression envisagé

#### 4.4.2.2 Compression des interfaces

Comme détaillé dans le chapitre 2 sur l'état de l'art, il existe de nombreuses méthodes pour la modélisation et la représentation de courbes. Cependant, que ce soit une approximation par polynômes, par Splines ou encore par primitives géométriques, le nombre de paramètres nécessaires à la modélisation est fonction de la complexité (irrégularité) de la courbe étudiée. L'approche fractale est privilégiée pour générer des courbes complexes avec peu de paramètres. Toutefois, pour un nombre de paramètres fixés, ces méthodes ne permettent de générer qu'un ensemble limité de courbes.

[Portefaix, 2004] propose une modélisation de courbes par IFS. Dans une première approche, il explicite analytiquement le calcul des paramètres des

transformations de l'IFS à partir du signal initial. Prenons l'exemple de la Figure 73. Le calcul des moments géométriques, ou des coefficients de Fourier, du signal original nous permet d'estimer les paramètres d'un IFS à 2 transformations (2x3 paramètres). L'attracteur de cet IFS correspondant alors à un signal très proche du signal.

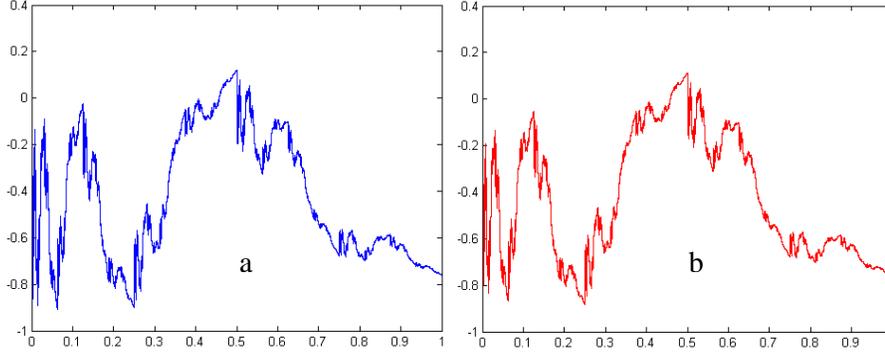


Figure 73 : Signal initial (a) et signal approché (b) par l'IFS défini par les deux transformations suivantes :

$$T1 \left| \begin{array}{l} [0,1[ \times \mathfrak{R} \rightarrow [0,1/2[ \times \mathfrak{R} \\ ((x, y) \times \mathfrak{R} \rightarrow (x/2, a_1 y + b_1 + c_1 x) \end{array} \right. \quad T2 \left| \begin{array}{l} [0,1[ \times \mathfrak{R} \rightarrow [1/2,1[ \times \mathfrak{R} \\ ((x, y) \times \mathfrak{R} \rightarrow (x/2 + 1/2, a_2 y + b_2 + c_2 x) \end{array} \right.$$

avec  $a_1 = -0,927$  ;  $b_1 = -0,965$  ;  $c_1 = 0,373$  ;  $a_2 = -0,378$  ;  $b_2 = -0,230$  et  $c_2 = -0,815$ .

Les paramètres  $a_i$ ,  $b_i$  et  $c_i$  ont été estimés à partir des moments d'ordre 1 à 6 calculés sur la courbe initiale. Le signal de départ correspond, quant à lui, à l'attracteur de l'IFS à deux transformations :  $a_1 = -0.95$ ,  $b_1 = -0.97$ ,  $c_1 = 0.37$ ,  $a_2 = -0.37$ ,  $b_2 = -0.23$  et  $c_2 = -0.81$ . Afin de permettre de calculer mathématiquement les paramètres  $a_i$ ,  $b_i$  et  $c_i$ , à partir d'une courbe, les relations 1 à 6 ont été établies. Ces relations, reliant les moments théoriques ( $\mu_i$ ) et les paramètres de l'IFS, ont été établies [Portefaix, 2004] :

$$(2 - a_1 - a_2)\mu_0 = b_1 + b_2 + c_1/2 + c_2/2 \quad (1)$$

$$(2^2 - a_1 - a_2)\mu_1 + a_2\mu_0 = b_1/2 + (3/2)b_2 + c_1/3 + (5/6)c_2 \quad (2)$$

$$(2^3 - a_1 - a_2)\mu_2 - a_2(2\mu_1 + \mu_0) = b_1/3 + (7/3)b_2 + c_1/4 + (17/12)c_2 \quad (3)$$

$$(2^4 - a_1 - a_2)\mu_3 - a_2(3\mu_2 + 3\mu_1 + \mu_0) = b_1/4 + (15/4)b_2 + c_1/5 + (49/20)c_2 \quad (4)$$

$$(2^5 - a_1 - a_2)\mu_4 - a_2(4\mu_3 + 6\mu_2 + 4\mu_1 + \mu_0) = b_1/5 + (31/5)b_2 + c_1/6 + (43/10)c_2 \quad (5)$$

$$(2^6 - a_1 - a_2)\mu_5 - a_2(5\mu_4 + 10\mu_3 + 10\mu_2 + 5\mu_1 + \mu_0) = b_1/6 + (21/2)b_2 + c_1/7 + (107/14)c_2 \quad (6)$$

Barnsley [Barnsley et al., 1989] a de plus démontré une relation supplémentaire sur les  $a_i$  :

#### 4.4 Éléments de Compression

$$\sum_i |a_i| \times \left(\frac{1}{2}\right)^{Dim-1} = 1 \text{ soit } Dim = 1 + \frac{\ln\left(\sum_i |a_i|\right)}{\ln(2)} \quad (7)$$

Où  $Dim$  correspond à la dimension fractale du signal que l'on cherche à reproduire via l'utilisation d'un IFS.

Cette relation très importante nous permet de conserver pour l'IFS calculé, une partie des caractéristiques du signal à reproduire ; l'attracteur de l'IFS ainsi généré sera donc un signal de complexité équivalente à celle du signal d'entrée. La connaissance de la dimension fractale du signal étudié nous permet donc théoriquement de contrôler l'aspect de l'attracteur recherché tout en limitant le nombre de paramètres inconnus de l'IFS.

Ainsi, nous pouvons en théorie calculer les moments théoriques attendus à partir de ces relations et inversement, déduire, d'un calcul de moments sur un signal donné, les paramètres d'un IFS. Cependant, comme proposé sur la Figure 74, la précision des moments observés sur la courbe initiale est fortement liée à la taille de l'échantillon proposé de la courbe initiale et plus précisément au nombre de points formant cet échantillon.

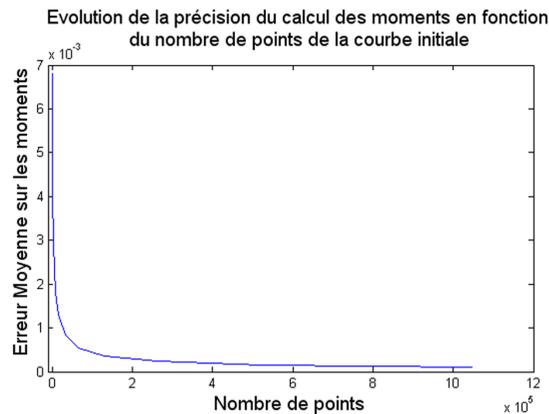


Figure 74 : Évolution de l'erreur moyenne sur l'estimation des moments théoriques à partir des moments calculés sur l'échantillon. Plus l'échantillon est important, plus la précision est grande.

Cet exemple montre la nécessité d'avoir un échantillon initial important pour trouver le résultat escompté. La Figure 75 illustre la répercussion d'un tel paramètre sur l'attracteur de l'IFS final estimé.

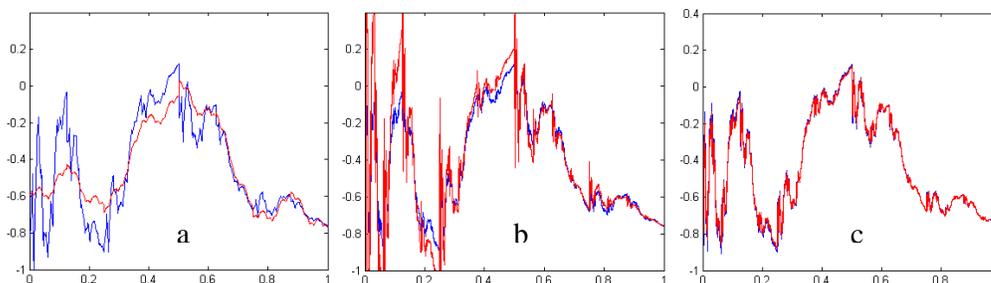


Figure 75 : Attracteurs des IFS estimés à partir de la courbe (a) de la Figure 73 pour des échantillonnages initiaux de  $2^{10}$  (a)  $2^{13}$  (b) et  $2^{18}$  points (c).

Une alternative à la mauvaise estimation des paramètres de l'IFS par la méthode des calculs des moments géométriques peut être l'analyse spatiale de la courbe dans sa globalité. Pour cela, nous proposons l'utilisation d'un algorithme génétique. Basée sur la minimisation d'une fonction coût, l'erreur des moindres carrés entre les courbes dans notre cas (par calcul des abscisses curvilignes), cette approche (présentée à la section 4.3.1.2), peut être utilisée. Les chromosomes regroupent alors les paramètres des transformations nécessaires à la définition de l'IFS ( $a_i$ ,  $b_i$  et  $c_i$ ). L'évolution « génétique » de la population nous permet, de proche en proche, de nous rapprocher d'une solution acceptable. Prenons par exemple l'échantillon à 1024 points de la Figure 75, l'algorithme génétique à 6 paramètres nous donne le résultat présenté sur la Figure 76.

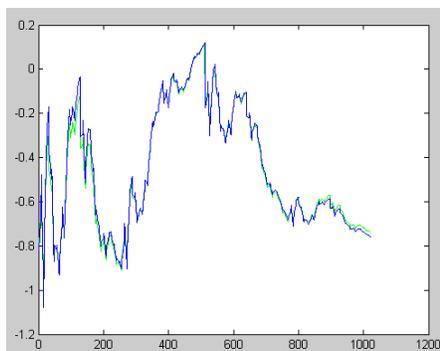


Figure 76 : Estimation, via l'utilisation d'un algorithme génétique, des paramètres de l'IFS à deux transformations (en vert) approximant la courbe initiale (en bleu).

Malheureusement, cette méthode, bien qu'intéressante de prime abord, montre rapidement ses limites lors de l'étude de cas plus complexes. En effet, la modélisation d'un signal d'entrée par un IFS à deux transformations ne conduit qu'à des cas particuliers dans un ensemble plus vaste. Nous aurons alors recours à des modèles plus complexes à 4 voire 8 transformations pour modéliser un ensemble plus vaste de signaux. La Figure 77a reprend la nécessité d'étendre l'analyse à des modèles plus complexes. Cependant, même si la recherche d'un IFS à 8 transformations permet d'améliorer les résultats dans la plupart des cas, nous ne faisons qu'étendre l'ensemble des courbes que

#### 4.4 Éléments de Compression

nous pouvons générer sans jamais être capable de modéliser toutes les courbes que nous souhaiterions.

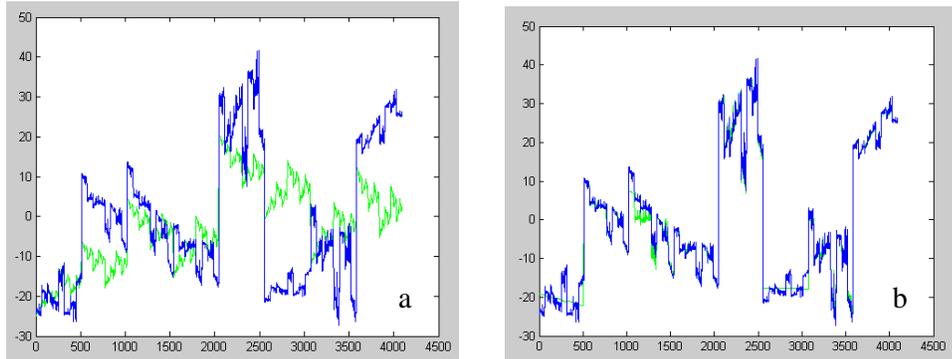


Figure 77 : Courbe approchée par des IFS respectivement, de gauche à droite, à 2 (a) puis 8 (b) transformations.

A l'instar des harmoniques de Fourier pour lesquelles les hautes fréquences ajoutent du détail au signal, plus l'IFS sera composé d'un grand nombre de transformations, plus il sera possible de générer des signaux différents. Comme le laisse entendre la Figure 78, le modèle à 8 transformations présente lui aussi des limites dans l'approximation. Trouver un modèle complet semble alors chose délicate en restant dans ce cadre.

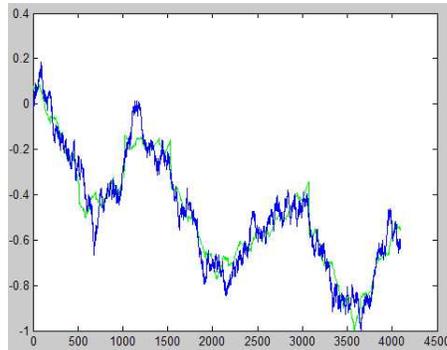


Figure 78 : Approximation d'un signal Brownien par un IFS à 8 transformations

Portefaix, dans [Portefaix, 2004], propose alors de limiter le nombre de transformations, par exemple à 4, et d'appliquer la méthode sur tout ou partie du signal d'entrée. Via l'utilisation d'une approche de type « quadtree », le signal initial va être découpé en morceaux modélisables par le modèle choisi. Plus précisément, l'auteur essaie tout d'abord de synthétiser le signal de départ dans sa globalité. Si l'erreur quadratique entre l'attracteur de l'IFS calculé et le signal initial est trop importante, il subdivise le signal initial en deux parties. Il applique alors de façon récursive cette approche sur chacune des deux parties, tout en limitant le nombre de subdivisions possibles de l'ensemble initial (donc la taille du plus petit échantillon). Bien évidemment, réduire le nombre de points du signal initial, comme illustré à la Figure 75, rend l'approximation des portions de courbe de plus en plus délicate. Le reste

comporte alors des portions linéaires pour approximation, ne reflétant plus la complexité du signal initial.

Si l'on devait faire un bilan sur cette méthode, nous devons tenir compte à la fois de l'approximation de la courbe et du taux de compression. En effet, cette méthode permet de compresser des signaux avec des taux très importants. Les exemples des Figure 75c et Figure 77b, nous donnent des taux de compression de l'ordre de 240000 et 170 respectivement. Il est de plus possible d'améliorer le taux de compression d'un facteur 4 par l'application d'une phase de « quantification » supplémentaire [Fisher, 1998]. Néanmoins, ce fort taux de compression n'est atteint que pour un ensemble restreint de courbes. Plus généralement, [Portefaix, 2004] se retrouve dans l'obligation de partitionner le signal initial en morceaux, de multiplier les IFS, et donc d'augmenter la quantité d'information nécessaire au codage. De plus, l'attracteur final obtenu ne conserve plus forcément les propriétés (complexité) du signal initial.

A titre de comparaison et dans la recherche d'une approximation maximale conservant les caractéristiques du signal de départ, nous nous sommes orienté vers une deuxième approche : les fractals à pôles. Initialement développée au LIGIM de Lyon [Zair, 1998], cette méthode consiste à conjuguer le fort taux de compression des IFS au suivi de courbe permis par l'utilisation de points de contrôle appelés « pôles ». Tout comme pour la méthode détaillée dans [Portefaix, 2004], le signal final correspond à l'attracteur d'un IFS défini par un ensemble de transformations  $T_i$ . Dans le cadre des fractales à pôles, ces transformations correspondent à des matrices carrées appelées « matrices de subdivision ». La grande différence avec l'approche de Portefaix réside dans l'utilisation de points de contrôle. Ils permettent de manipuler la courbe synthétisée par l'IFS et d'ajuster son comportement (global ou local selon le type de transformation envisagé). La Figure 79 est un exemple de courbe simple approchée par un IFS à deux transformations (matrice de subdivision  $4 \times 4$ ) et 4 points de contrôle. Le signal final est alors codé sous la forme de 26 paramètres pour un signal initial composé de 1024 points et ce avec une distance finale de l'ordre de  $3 \times 10^{-4}$  (moindres carrés sur les abscisses curvilignes).

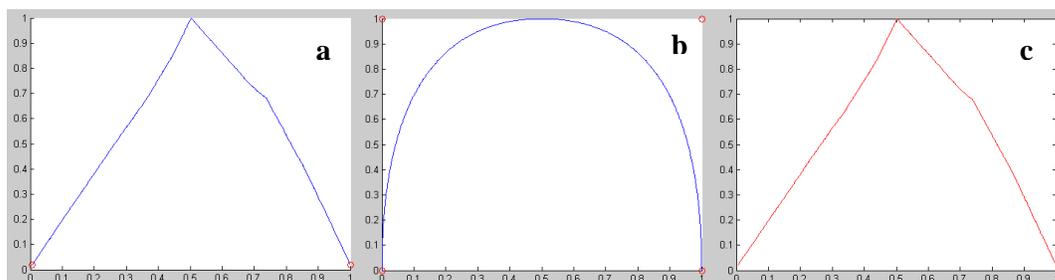


Figure 79 : Courbe simple approchée par un IFS à pôles.

(a) : Signal à approximer

#### 4.4 Éléments de Compression

(b) : Initialisation des pôles et de la courbe recherchée.

(c) : Courbe synthétisée avec 2 matrices de subdivision ( $4 \times 4$ ) et 4 points de contrôle. La distance entre les courbes (a) et (c) est de 0,00031.

L'approximation de courbes, soit la recherche des paramètres de l'IFS (des matrices de subdivision) et des points de contrôle, s'effectue via l'algorithme de Levenberg-Marquardt [Levenberg, 1944]. Basée sur la minimisation d'une fonction, ici la distance entre les courbes recherchée et synthétisée, cette méthode nous permet de déterminer de façon itérative un jeu de paramètres offrant une bonne estimation.

Pour plus de détails sur l'approximation de courbes par la méthode des fractales à pôles, se référer à [Guérin, 2002]. Il propose notamment un calcul de distance entre lignes brisées des deux courbes étudiées et démontre sa dérivabilité aux ordres 1 et 2. Les calculs des dérivées du premier et second ordres sont nécessaires pour l'utilisation de la méthode de Levenberg-Marquardt.

La Figure 80 reprend deux exemples d'IFS obtenus sur deux types de signaux : un signal globalement régulier et un signal Brownien. Les limitations du modèle proposé à la Figure 79, nous ont poussé à adopter un modèle à 3 transformations ( $T_i$  de dimension  $6 \times 6$ ) et 6 points de contrôle. On se retrouve alors visuellement avec un résultat similaire à celui proposé à la Figure 78. Ainsi, tout comme avec la méthode de Portefaix, le résultat semble être fonction du nombre de transformations envisagées. De plus, les nombreux tests effectués nous renforcent dans l'idée d'une dépendance entre la qualité du résultat et l'initialisation des paramètres de l'algorithme.

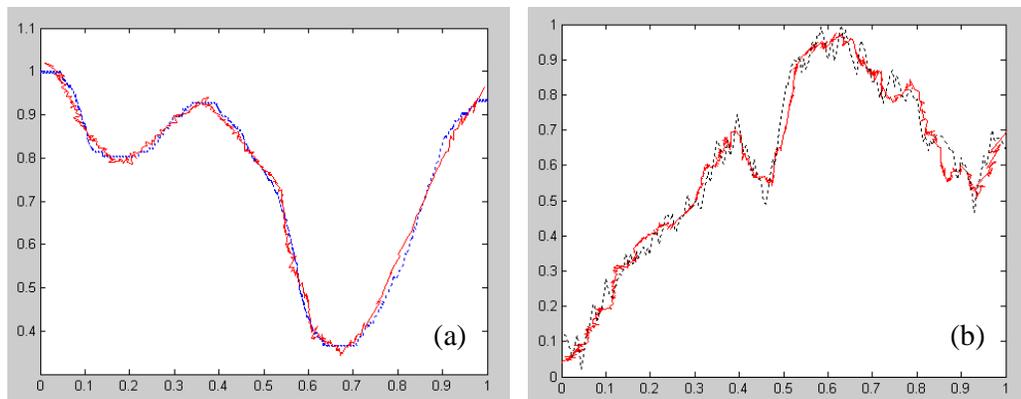


Figure 80 : Courbes bleues (en pointillés) approximées par des IFS à pôles : 3 matrices de subdivision et 6 points de contrôle nécessaires (82 paramètres) pour modéliser ces signaux.

(a) : Signal initial lisse (erreur quadratique entre les deux signaux de 0,0262)

(b) : Signal représentant un mouvement Brownien (erreur quadratique constatée de 0,55)

Ainsi, la compression d'un signal semblable aux interfaces proposées semble délicate à réaliser. En effet, que ce soit avec l'une ou l'autre des méthodes présentées ici, le choix du nombre de paramètres reste difficilement automatisable. Une corrélation entre le nombre de paramètres (transformations et/ou points de contrôle) nécessaires pour la synthèse d'une courbe approchée et la dimension fractale de la courbe initiale pourrait être réalisée et étudiée. Cependant, ce travail ne sera pas abordé dans ce document.

Pour conclure, nous pouvons dire que l'utilisation de telles compressions par IFS ([Portefaix, 2004], fractales à pôles) reste limitées à un ensemble trop restreint de courbes. dans notre application semble compromise. En effet, les multiples approximations sur les différentes composantes connexes extraites de la segmentation nous amèneraient à une trop grande imprécision dans la localisation des interfaces. Dans le cadre d'un exemple applicatif, tout en préservant la démarche globale de l'étude, nous avons effectué une simple compression de l'image binaire, algorithme deflate de Winzip (combinaison des algorithmes LZ77 et Huffman), représentant les différentes interfaces (Figure 81).

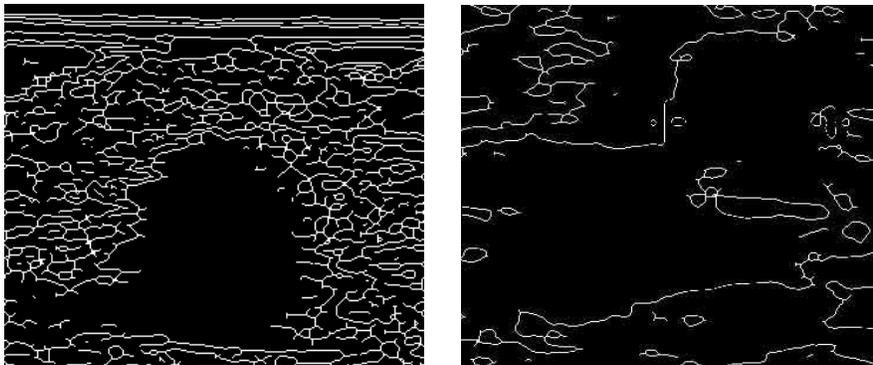


Figure 81 : Exemple de cartes d'interfaces obtenues à partir, respectivement, des transitions obtenues sur la Figure 64 et la Figure 47.

#### 4.4.2.2.3 Compression des milieux

Les milieux pouvant être assimilés à des textures plus ou moins homogènes, nous allons les considérer comme tels.

Les méthodes de modélisation par calcul de champs de Markov permettent d'analyser une grande variété de textures. Cependant, le temps nécessaire au calcul des probabilités du modèle n'est souvent pas acceptable. Nous ferons le choix ici de l'utilisation de l'algorithme présenté dans la thèse de Li-Yi Wei [Wei, 2002]. Li-Yi Wei propose une méthode de synthèse permettant de se passer du calcul des probabilités tout en conservant l'idée de dépendance locale entre un pixel et ses voisins.

Soient (Figure 82) :

- $I_0$ , l'image initiale de texture à reproduire.

#### 4.4 Éléments de Compression

- $I_f$ , une image initialisée par du bruit.

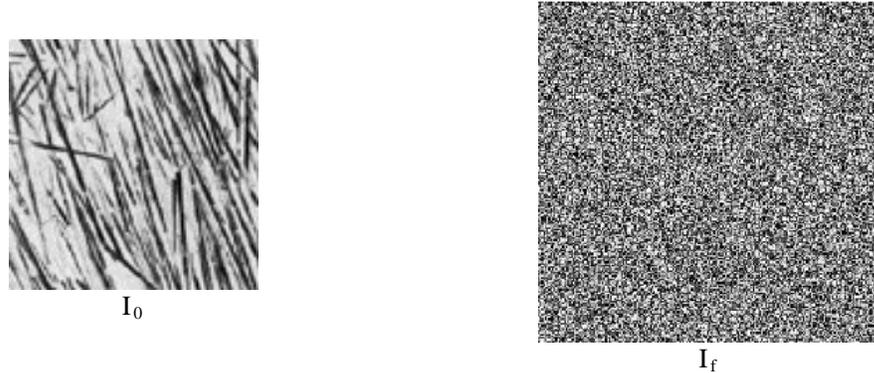


Figure 82 : Image initiale à dupliquer  $I_0$  et image  $I_f$  initialisée par du bruit uniforme (chaque classe de niveau de gris contient le même nombre d'individus).

L'histogramme des niveaux de gris de  $I_f$  est alors égalisé, modifié, de façon à lui faire correspondre celui de  $I_0$  (Figure 84). On obtient alors l'image  $I_f^*$  (Figure 83). Pour plus de finesse, une approche multi résolutions peut être effectuée

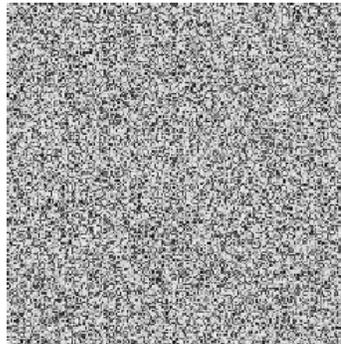


Figure 83 :  $I_f$  de la Figure 82 modifiée en  $I_f^*$  suite à l'égalisation d'histogramme par rapport à  $I_0$

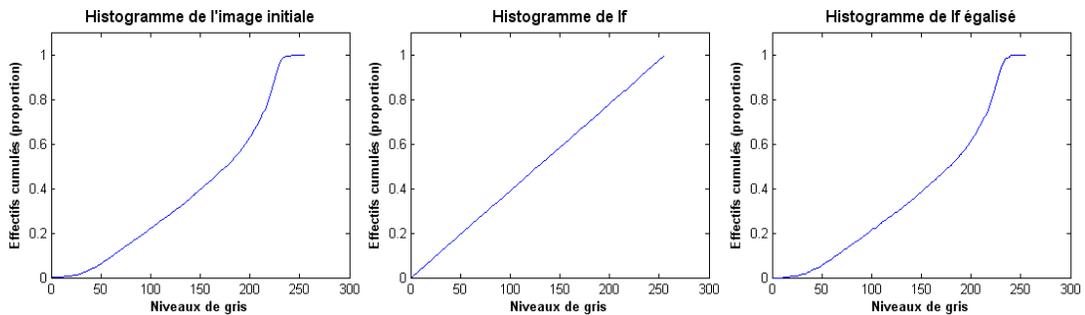


Figure 84 : Égalisation de l'histogramme de l'image  $I_f$  de la Figure 82 par rapport à celui de  $I_0$ .

L'étape suivante consiste à parcourir  $I_f^*$  et à modifier chacun de ses éléments de façon à se rapprocher de  $I_0$ . Chaque pixel voit alors la valeur de son niveau de gris modifiée en fonction de celles de ses pixels voisins. Le

processus s'effectue à l'aide d'un voisinage anisotrope comme utilisé à la Figure 85. Les niveaux de gris des pixels voisins sont alors regroupés sous forme d'un vecteur (Figure 85).

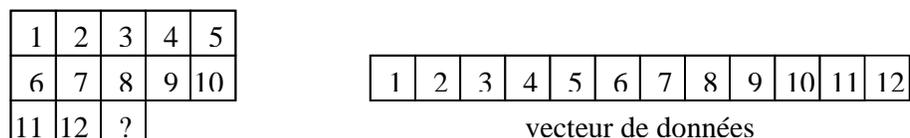


Figure 85 : Voisinage anisotrope et vecteur de données associé.

Ce vecteur est alors comparé avec ceux obtenus de la même manière en chacun des pixels de l'image  $I_0$ . La distance entre les deux vecteurs de données est calculée sous forme d'une erreur quadratique. Le pixel de  $I_f^*$  étudié prendra alors la valeur de niveau de gris du pixel de  $I_0$  pour lequel la distance entre les vecteurs « de voisinage » respectifs est minimale.

Remarque :

La comparaison d'un vecteur avec la base de vecteurs extraite depuis l'image  $I_0$ , soit autant de vecteurs qu'il y a de pixels dans l'image, est gourmande en temps de calcul. Une solution consiste à effectuer un arbre de recherche dans l'ensemble des vecteurs ainsi constitué. La méthode préconisée est la méthode TSVQ Tree-Structured Vector Quantization [Gersho et Gray, 1993]. Le vecteur solution ainsi obtenu n'est pas forcément la solution optimale à la recherche du vecteur le plus proche dans l'ensemble de départ mais fournit une bonne solution en un temps réduit de calcul.

Quelques résultats obtenus sur des textures de Brodatz [Brodatz, 1966] sont représentés sur la Figure 86.

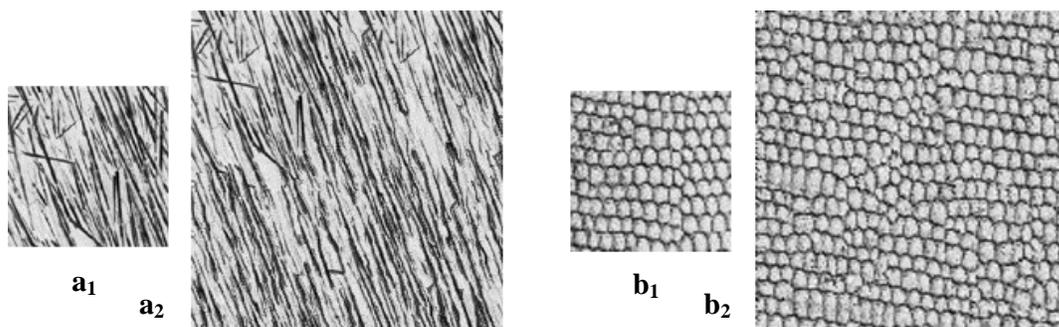


Figure 86 : Exemple de texture reconstruite correctement par l'algorithme de Li-Yi Wei simple résolution. Les images  $a_1$  et  $b_1$  correspondent aux textures à dupliquer et les figures  $a_2$  et  $b_2$  aux résultats de synthèse.

#### 4.4 Éléments de Compression

Voisinage anisotrope choisi :

```

× × × × × × ×
× × × × × × ×
× × × × × × ×
× × × ○

```

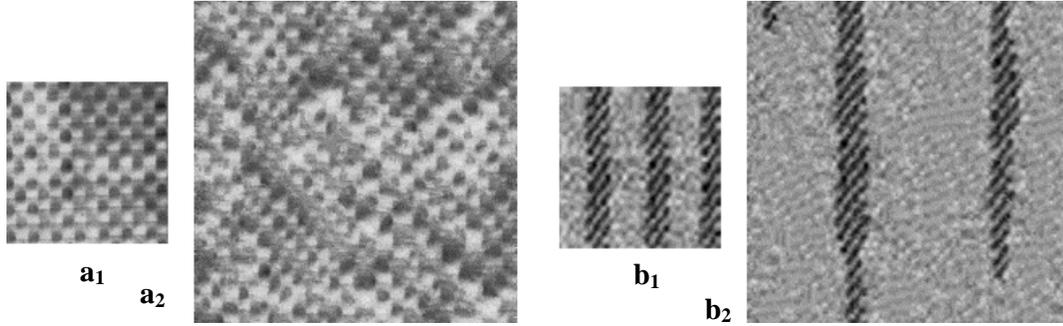


Figure 87 : Exemple de texture reconstruite de façon incorrecte par l'algorithme de Li-Yi Wei en simple résolution. Les images  $a_1$  et  $b_1$  correspondent aux textures à dupliquer et les figures  $a_2$  et  $b_2$  aux résultats de synthèse.

En l'état, on constate très nettement sur les exemples de la Figure 86 que la méthode permet de gérer les textures microscopiques où l'aspect statistique est prédominant. Par contre, la Figure 87b montre très clairement la difficulté de la méthode pour analyser les textures structurales macroscopiques. Comme solution, Li-Yi Wei propose deux méthodes : la première consiste à augmenter la taille du voisinage et la seconde à utiliser une analyse multi-résolution de la texture (revenant à limiter la taille du voisinage pour obtenir un résultat similaire en simple résolution). La Figure 88 est un exemple de résultats obtenus pour un voisinage plus important.

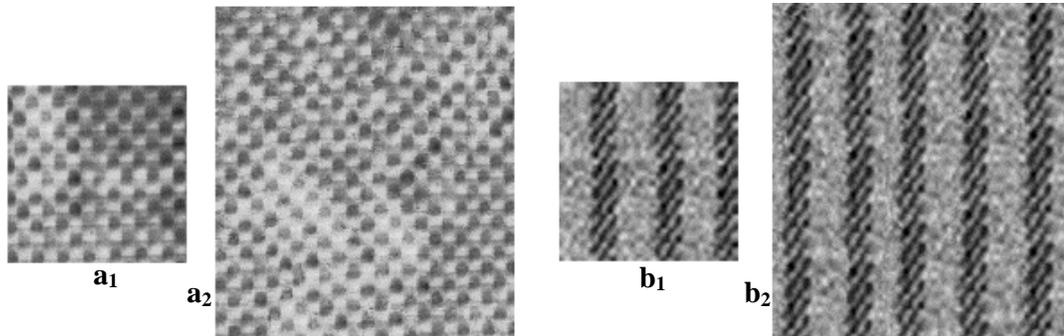


Figure 88 : Exemple de textures reconstruites par l'algorithme de Li-Yi Wei (voisinage anisotrope  $9 \times 17$ ). Les images  $a_1$  et  $b_1$  correspondent aux textures à dupliquer et les images  $a_2$  et  $b_2$  aux résultats de synthèse.

La méthode de Li-Wei permet donc bien de synthétiser une image texturée de dimension quelconque à partir d'un échantillon de la texture. Nous pouvons alors légitimement nous poser des questions sur l'influence de la taille de l'échantillon initial sur le résultat. Nous avons donc effectué une étude

complémentaire visant à synthétiser une image de texture à partir de divers échantillons de tailles différentes à la recherche de la taille minimale nécessaire au bon fonctionnement. Nos expérimentations nous permettent de conclure qu'un échantillon comprenant quelques occurrences de la primitive de base est suffisant.

La phase de validation de la méthode effectuée sur un ensemble d'images synthétiques, nous l'avons alors appliquée à quelques images ultrasonores. La Figure 90 présente la synthèse de texture réalisée par la méthode de Li-Wei sur les échantillons prélevés à la Figure 89. Les résultats obtenus semblent acceptables.

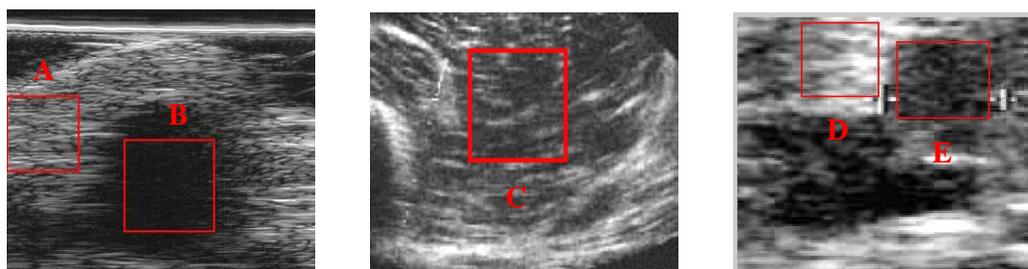


Figure 89 : Echantillons de textures prélevés (A, B, C, D et E en rouges) sur des images ultrasonores afin d'être reproduites à plus grande échelle par la méthode de Li-Wei.

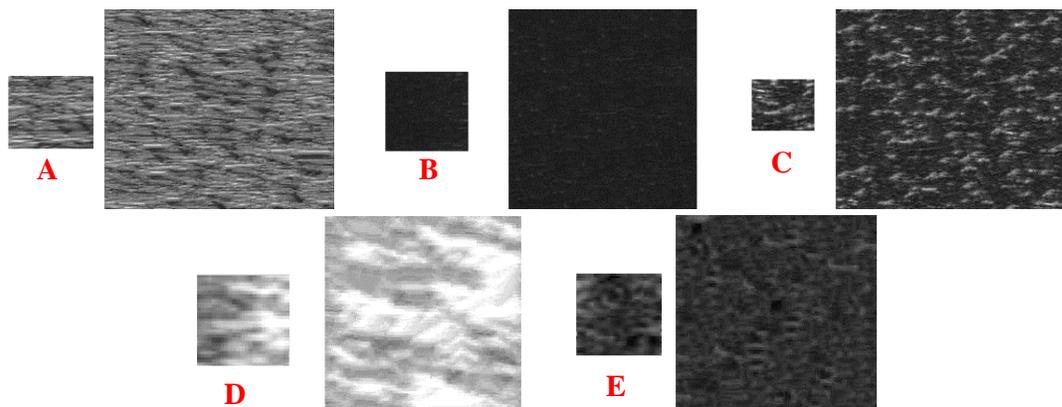


Figure 90 : Synthèse de texture à partir des échantillons (A,B, C, D et E) prélevés à la Figure 89.

#### 4.4.2.2.4 Exemples de compression

Les exemples suivants s'appuient sur l'ensemble des résultats obtenus précédemment sur la modélisation de courbes et la synthèse de textures. Nous proposons ici d'étudier un cas théorique, correspondant à la compression d'une image représentant deux milieux texturés (synthétisés à partir des textures de l'album de Brodatz) avant de passer à la compression d'une image ultrasonore.

(a) Compression d'une image synthétique.

#### 4.4 Éléments de Compression

Débutons par la compression de l'image synthétique. La Figure 91a présente un exemple d'image texturée étudiée au chapitre précédent. On retrouve l'interface obtenue via l'utilisation de la méthode proposée au chapitre 2 (Figure 91b).

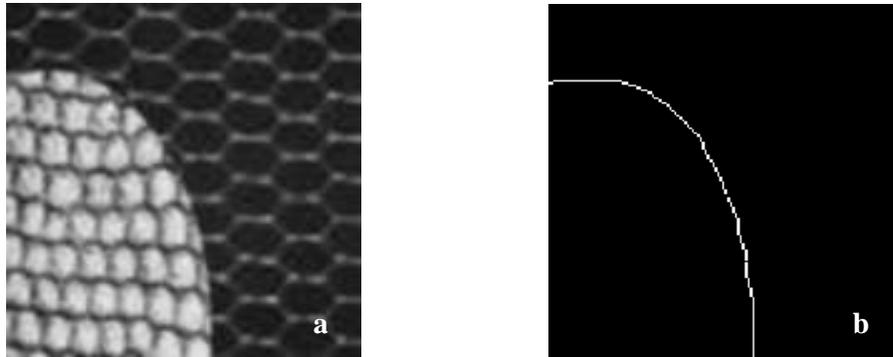


Figure 91 : Image initiale (a) et interface extraite (b) entre les deux milieux texturés ( $R=12$  et  $k=0,03$ ).

Les différents composants d'une telle image vont alors être compressés différemment. Pour les interfaces, nous proposons d'utiliser la méthode des IFS à pôles. Cette méthode nous permet d'approcher l'interface à estimer avec un minimum de paramètres. La Figure 92 est un exemple d'IFS à 2 transformations et 4 points de contrôle (soient 29 paramètres) approchant l'interface présentée à la Figure 91b. Cet exemple nous permet d'approcher une interface constituée dans ce cas précis de 147 points.

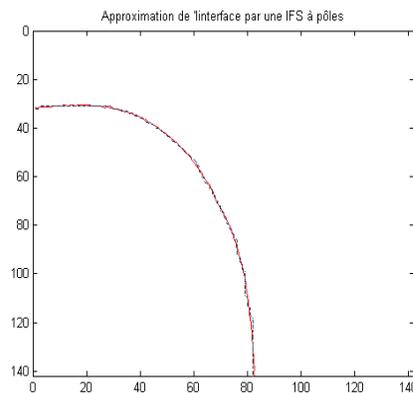


Figure 92 : Approximation de l'interface de la Figure 91b. L'IFS à 29 paramètres proposé est obtenu par la méthode de Levenberg-Marquardt.

Une fois l'interface modélisée, le fichier final compressé comprend :

- \_ Les paramètres de l'IFS (29 dans le cas présent) modélisant l'interface.
- \_ Les différents échantillons de textures présentes dans l'image (40x40 pixels pour la texture claire et 60x60 pixels pour la texture sombre ici);
- \_ Une carte grossière de l'emplacement des diverses textures de l'image à compresser (ici, deux points, appartenant respectivement à l'un et l'autre des deux milieux, suffisent pour définir cette carte).

La phase de décompression débute alors par la génération d'une carte des frontières à partir des diverses IFS comme suggéré à la Figure 92 ; vient ensuite la phase de la synthèse de textures. La Figure 93 regroupe les synthèses de textures obtenues à partir des deux milieux de l'image de la Figure 91a.

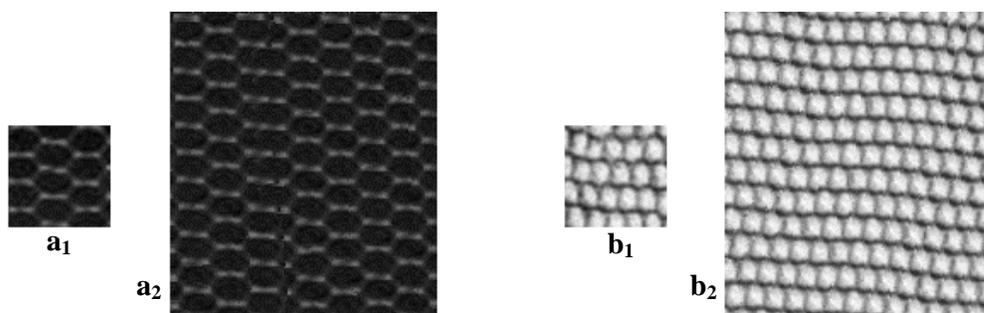


Figure 93 : Textures synthétisées ( $a_2$  et  $b_2$ ) à partir d'échantillons ( $a_1$  et  $b_1$ ) par application de la méthode de Li-Wei (voisinage de  $20 \times 20$  utilisé pour la synthèse de  $a_2$  et  $8 \times 8$  pour  $b_2$ ). Les échantillons de départ sont constitués chacun de  $40 \times 40$  pixels.

Une carte des contours sur laquelle figurent quelques indications simples de positionnement des diverses textures est alors utilisée pour synthétiser l'image finale. Le résultat obtenu est présenté à la Figure 94.

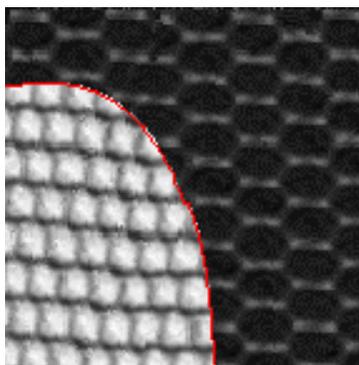


Figure 94 : Image reconstruite après décompression.

Le temps de compression n'est actuellement pas pris en compte et l'algorithme ne pourrait être utilisé que pour l'envoi d'une image ou d'une séquence dans le cadre d'un traitement distant effectué en différé. En effet, l'application temps réel n'est pas envisagée dans notre étude. Nous nous sommes donc intéressés aux taux de compression atteignables. Avec cette approche, nous pouvons, à l'issue du partitionnement de l'image en régions, différencier la compression des interfaces et des milieux. Pour le résultat de la Figure 91a, nous atteignons un taux global de compression de 10 sans réellement chercher à optimiser ce résultat. Fixées sur cet exemple à  $40 \times 40$  pixels pour la texture claire et  $60 \times 60$  pixels pour la texture sombre (maillage plus large), une minimisation de ces tailles d'échantillons pourrait être menée afin d'amplifier le taux de compression. Une autre façon d'augmenter ce taux

#### 4.4 Éléments de Compression

sans pour autant dégrader le résultat obtenu après décompression serait l'utilisation d'une méthode de compression sans perte sur les échantillons. En effet, le partitionnement de l'image en régions homogènes amplifie l'efficacité de ces méthodes basées sur la redondance spatiale des éléments (attributs).

##### (b) Traitement d'une image ultrasonore.

Nous proposons d'étudier la compression de l'image échographique de la Figure 64. Cet exemple a pour but de présenter l'approche sans pour autant avoir la prétention d'être une méthode finalisée prête à être évaluée et comparée en l'état. Comme explicité en introduction, il s'agit ici d'une première étape à la compression, possible application de nos travaux sur la caractérisation des composants d'une image échographique. Nous laissons le soin à de futurs travaux d'effectuer les évaluations et modifications du principe de compression proposé.

Reprenons les différentes étapes du schéma de compression à partir de l'image initiale : la première étape consiste en la recherche du nombre de milieux composant l'image (section 4.3.1) ; une fois les milieux clairement identifiés, la phase suivante consiste, pour chaque couple de milieux (section 4.3.2), à en extraire leur interface. Cela est rendu possible par le calcul des coefficients de pureté de chaque pixel de l'image aux deux milieux de référence formant le couple actuel (section 3.3.1.4). Les pixels de coefficient de pureté minimum formant une zone nommée « transition » (section 3.3.2.1), non clairement identifiée comme une interface, une phase de squelettisation est appliquée (section 3.3.2.2). En employant la méthode sur chaque couple de milieux, nous obtenons au final une carte des contours similaire à celle proposée à la Figure 81. C'est cette carte des interfaces qui, en plus des échantillons de textures prélevés sur l'image d'origine (Figure 89), va être compressée.

Le fichier ainsi compressé va contenir :

- la carte des interfaces : image binaire pouvant être réduite facilement à quelques kilo-octets (ko) par un algorithme standard tel que celui de Huffman se basant sur la redondance des éléments. (6 ko dans le cas de la Figure 81).
- quelques coordonnées de points nous permettant de replacer les textures synthétisées via la méthode de Li-Wei (section 4.4.2.2.3), sur la carte des interfaces (une centaine de cas dans l'exemple de gauche de la Figure 81 soit environ 1 ko que l'on pourrait compresser d'avantage à l'aide d'un algorithme sans perte supplémentaire).
- les divers échantillons de texture à dupliquer. Ces échantillons, de taille initiale fixe (50x50 pixels pour le cas de la Figure 96a et 25x25 pour le cas de la Figure 96b), peuvent être, à leur tour, compressés par un algorithme de compression type Jpeg/Jpeg2000 ou un algorithme de compression sans perte quelconque. Nous ne tiendrons pas compte de

cette possibilité dans notre bilan de compression. Nous arrivons à une taille de 10ko pour la compression des 4 textures de dimension 50x50 pixels contre 2,5Ko pour les textures de dimension 25x25 pixels.

Les résultats de la phase de décompression sont présentés Figure 96 (a) et (b).

Une première évaluation du taux de compression atteignable pour cette figure échographique peut être donnée en effectuant le rapport entre la taille du fichier compressé (la carte des interfaces à 6ko, les 100 points nécessaires à l'initialisation des textures à 1ko et les échantillons) et la taille de l'image à compresser (76ko). On obtient au final les rapports :  $(6+1+10)/76=0,22$  et  $(6+1+2,5)/76=0,125$  comme taux de compression, respectivement pour les cas (a) et (b) de la Figure 96.

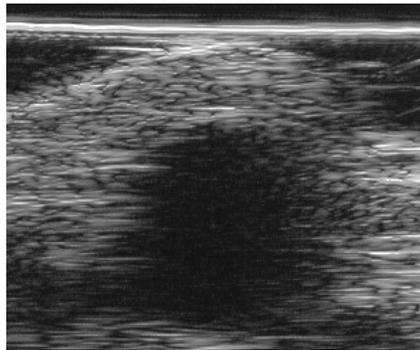


Figure 95 : Image initiale à compresser

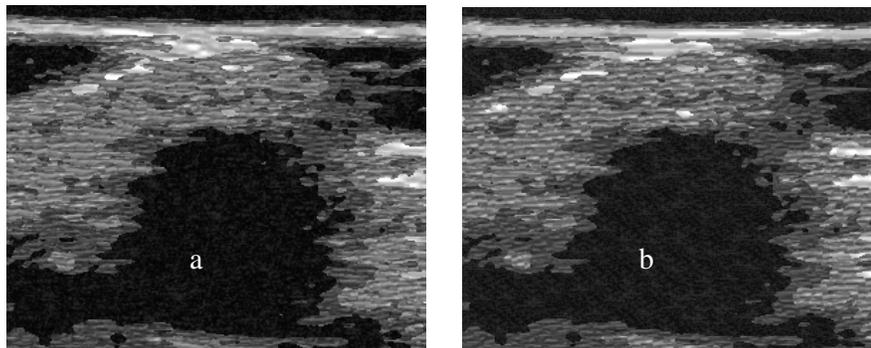


Figure 96 : Exemple d'images restituées suite aux phases de compression et décompression appliquées à partir de l'image de la Figure 95. L'image (a) a été compressée en prenant en considération des échantillons de taille 50x50 pixels contre des échantillons de 25x25 pixels pour le cas (b).

Cette première approche offre, un taux de compression relativement similaire à la méthode Jpeg (taux de compression à 0,125 pour la Figure 97a par une compression Jpeg à faible qualité d'image restituée). Cependant, et suite aux remarques précédentes, elle paraît prometteuse quand à l'amélioration de son taux de compression. En effet, de nombreuses améliorations sur la compression

#### 4.4 Éléments de Compression

des divers éléments (échantillons, carte d'interfaces et points de référence pour les textures) peuvent être apportées (compression sans perte notamment) et offrir un gain significatif sur la compression globale. Nous pensons notamment à la compression des différentes interfaces de l'image (sur les 10ko correspondant au fichier compressé, 6ko sont utilisés pour la compression des interfaces) par une méthode fractale pour les composantes connexes de grandes dimensions uniquement ou encore le choix de la dimension et/ou de la compression des échantillons de texture prélevés sur l'image originale.

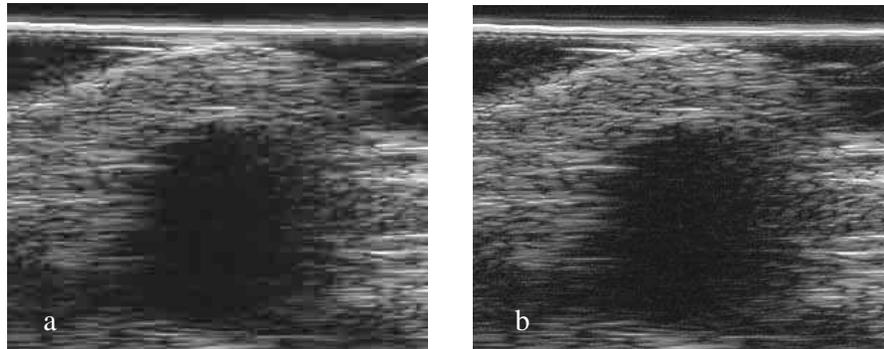


Figure 97 : Compression de l'image de gauche de la Figure 96 via l'utilisation d'un algorithme Jpeg standard à forte compression (image (a) correspondant à un fichier compressé réduit à 10 ko) et moyenne compression (image (b) de taille 19 ko).

Revenons maintenant sur la qualité visuelle de l'image restituée (Figure 96 a et b). L'image, bien que fortement dégradée, peut être suffisante lors de la phase de navigation à la recherche de la meilleure incidence d'observation. Contrairement aux autres formats de compression tels que le Jpeg2000 ou encore le Jpeg (illustré Figure 97a et Figure 97b), notre méthode (Figure 96a et Figure 96b) ne cherche pas à restituer avec exactitude l'image initiale (Figure 95) mais une image plus nette, faisant apparaître de façon plus claire les différentes structures la composant.

La perte de détail ainsi engendrée se situe donc en grande partie dans les zones de transitions entre les milieux de l'image originale. La Figure 98 illustre ce phénomène en masquant volontairement les transitions entre les divers milieux de l'image initiale (Figure 95) comme sur l'image reconstituée (Figure 96 a). La différence entre les deux images (Figure 98a et Figure 98b) devient visuellement difficile. Il serait donc intéressant, dans le cadre de la recherche de l'image la plus proche possible de l'image originale, d'appliquer un filtre permettant d'ajouter du flou sur l'image reconstituée au niveau des zones de transitions. Nous pourrions par exemple appliquer un filtre gaussien sur les points voisins de ceux appartenant à la carte des interfaces dans un rayon R correspondant à l'échelle d'observation avec laquelle l'image originale a été compressée. Cela nous amènerait à reproduire le flou que nous avons volontairement essayé de supprimer afin de privilégier l'image (Figure 95) familière avec laquelle se confronte l'expert quotidiennement.

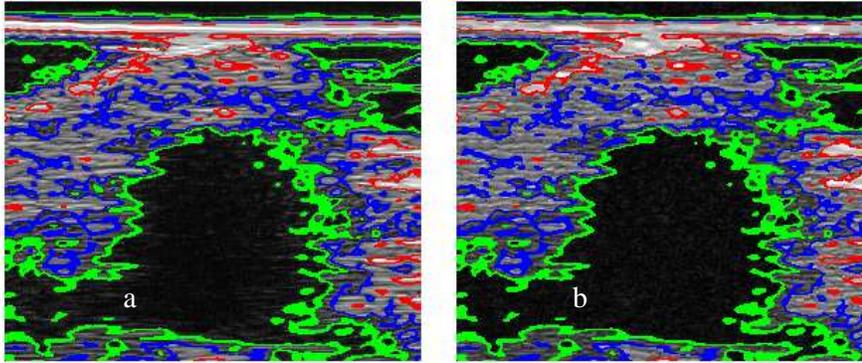


Figure 98 : Image initiale (a) et image issue de la décompression (b) sur lesquelles sont représentées les transitions entre les divers milieux constituant l'image originale.

Apportons maintenant quelques informations concernant une possible phase de validation de la méthode. De par la construction même de l'image décompressée (plaquage de texture), l'utilisation d'une méthode d'évaluation automatique du résultat type PSNR comparant les pixels un par un entre l'image originale et l'image reconstruite serait aberrante. Une des solutions envisageable consiste à se référer au corps médical. Le protocole utilisé, mais surtout la problématique de départ, ont de l'importance. La problématique, dont découlera le protocole expérimental, peut être de deux natures différentes selon le besoin. Par exemple : « Quelle est l'image, parmi celles obtenues par différentes méthodes de compression, la plus proche de l'originale ? » ou « Quelle image répond le plus à l'application désirée (par exemple la navigation 2D dans un environnement 3D) ? ». Dans les deux cas, une série d'images va alors être présentée à différents experts qui donneront des notes, des avis quantifiés, aux diverses images. La différence se situera sur la référence ; explicite dans le premier cas avec l'image originale pour comparer les autres méthodes et implicite dans le second cas (idée du cas idéal pouvant être biaisé par l'expérience passée). Au final, une étude statistique sur les différentes notes permettra alors de classer les méthodes de compression les unes par rapport aux autres.

## **4.5 Conclusion**

La méthodologie présentée de façon théorique au chapitre précédent, bien que généralisable à de nombreux types d'images, est appliquée au traitement des images médicales ultrasonores et des images de synthèse fortement texturées. Elle présente un triple intérêt :

- Le partitionnement de l'image ultrasonore en milieux et interfaces, ainsi que leurs caractérisations, permettent d'apporter des informations supplémentaires quantifiées à l'expert pour l'élaboration de son diagnostic médical. C'est un outil d'aide au diagnostic.
  
- Les caractéristiques des divers composants extraits ; ces informations peuvent contribuer à l'application d'une méthode de compression adaptée

## 4.5 Conclusion

au contenu. Les méthodes fractales de compression envisagées, bien qu'actuellement limitées par la taille du modèle, devraient pouvoir être développées et permettre d'atteindre des taux de compression intéressants.

- La combinaison des divers résultats obtenus, caractérisation comme segmentation, permet d'envisager une amélioration du contrôle dans la chaîne de télé-échographie. Les données haptiques et l'image ultrasonore constituent actuellement les informations avec lesquelles l'expert, distant de plusieurs centaines de kilomètres du patient, manipule le bras robotisé vers l'organe recherché. Toute amélioration, dans l'interprétation de l'image elle-même, devrait donc permettre à l'expert d'avoir une meilleure représentation mentale de l'environnement dans lequel il navigue et donc une meilleure idée de la nouvelle orientation à donner.

Point de vue applicatif, nous pouvons soulever quelques remarques sur notre approche pour la compression d'une image ultrasonore :

- Les multiples interfaces complexes ou non, présentes dans une image multi milieu devraient rendre la compression délicate. Toutefois, la méthode fractale, capable de prendre en compte cette irrégularité reste un bon candidat à leur modélisation.
- On peut penser qu'un nombre élevé de milieux puisse limiter l'utilisation de l'application. Cependant, dans le cadre des images ultrasonores, une augmentation du nombre de milieux implique souvent un partitionnement de l'image en zones plus homogènes. Les échantillons de textures des milieux peuvent alors être réduits et l'utilisation d'un algorithme de compression sans perte, sur chaque échantillon, plus efficace.
- La synthèse des milieux lors de la compression n'étant pas effectuée à l'identique, l'utilisation d'un algorithme d'évaluation de compression basé sur la comparaison pixel par pixel entre l'image décompressée et l'image initiale, ne peut être pertinente. En effet, la texture synthétisée peut être tout simplement décalée par rapport à l'image originale.
- Une remarque importante consiste l'étude des interfaces discontinues. En effet, il est toujours possible de trouver une interface discontinue à caractériser, permettant les échanges entre les deux milieux frontaliers. Notre méthode restera dans ce cas fonctionnelle. En effet, le calcul de la dimension fractale de tels éléments nous donnera une dimension théorique inférieure à 1. Citons par exemple le cas de la poussière de Cantor, fractale représentant une courbe discontinue. Cette fractale possède une dimension de l'ordre de 0,63. La mesure de la complexité de telles interfaces peut alors rendre compte de la perméabilité de la surface.

## 5 Conclusion

Parmi nos travaux, nous pouvons distinguer une partie méthodologique, dans laquelle nous présentons l'intérêt d'approches floue et fractale, et une partie plus applicative justifiée par le cadre de la télé-échographie robotisée. Les images ultrasonores, de par leurs caractéristiques intrinsèques (bruit), sont souvent difficilement analysables par les méthodes de segmentation automatiques usuelles et, quelquefois même, par l'expert. Nous avons donc proposé, au travers divers outils de traitement, reprenant notamment certains aspects des théories floue et fractale, une démarche permettant de caractériser les divers composants de l'image étudiée. Cette méthode permet de pallier le fait que les méthodes de segmentation classiques, bien que pouvant être très efficaces dans certains domaines, ne sont pas adaptées au traitement des images ultrasonores ; ce sont des images dans lesquelles les contours entre objets restent très difficiles à appréhender de manière exacte et pour lesquelles, bien souvent, nous ne possédons pas de connaissance *a priori*.

De façon plus précise, la démarche développée nous a permis d'aborder trois aspects fondamentaux qui peuvent être appliqués dans de nombreux domaines:

- L'extraction, en utilisant une approche floue multi-échelle, des milieux et des transitions de l'image ; cela conduit à un partitionnement de l'image pouvant être utilisé en combinaison avec d'autres méthodes de segmentation.
- La caractérisation des divers composants ainsi extraits. Nous avons utilisé, pour cela, une approche fractale permettant de quantifier la complexité de phénomènes naturels. Cette caractérisation peut bien évidemment être utilisée par l'expert pour affiner son diagnostic ou encore en complément d'une méthode de compression adaptée au contenu.
- La prise en compte du bruit de l'image initiale. En proposant l'existence d'un lien unissant les approches floue et fractale, nous avons pu mettre en évidence leur interdépendance. Cela nous permet d'estimer les propriétés théoriques des objets présents, en d'autres termes, les caractéristiques que nous observerions pour une image initiale sans bruit (débruitée).

Bien évidemment, tous ces points laissent la place à de futurs travaux. De façon similaire au découpage auquel nous avons eu recours dans ce manuscrit, les perspectives suscitées par un tel travail peuvent être divisées en deux familles : les perspectives sur la partie théorique et celles sur l'utilisation (la pratique) d'une telle méthode.

Concernant l'approche théorique, d'autres études complémentaires devraient être menées :

\_ Sur le choix du coefficient de pureté de l'image utilisé. Nous avons choisi un coefficient de pureté assez simple mais d'autres définitions sont possibles. Il faudrait explorer le domaine et évaluer cette étape de notre méthode, en comparant des résultats, et peut être l'améliorer.

\_ Sur la mise en évidence du lien existant entre les approches floue et fractale. Le lien mis en évidence est une première approximation. Une étude plus poussée permettrait notamment de déterminer le champ d'application d'une telle relation.

Concernant les applications dans le cadre d'un transfert industriel, nous pouvons citer comme travaux à développer prochainement les éléments suivants :

\_ Nous n'avons fait que préparer la phase de compression. Elle reste à être mise en oeuvre. Deux approches sont alors possibles, soit définir une nouvelle méthode de compression par modélisation (fractale par exemple) des divers constituants de l'image, soit appliquer la caractérisation développée dans ce manuscrit comme prétraitement à une méthode de compression différente en espérant améliorer ses performances. On peut par exemple penser au format de compression JPEG-2000 ; ce format permet notamment la compression à différents taux de diverses régions d'une même image (communément appelées régions d'intérêt). Il est alors naturel de penser qu'une étude de la complexité des différentes zones à compresser (divers milieux et interfaces d'une image ultrasonore par exemple) permettrait d'adapter le taux de compression du JPEG-2000 de ces zones.

\_ L'implémentation sur la chaîne de télé-échographie robotisée. Cette application devrait permettre au médecin de se repérer plus facilement dans l'image visionnée et ainsi faciliter la phase fastidieuse de navigation, et ce, quelle que soit la bande passante disponible, jusqu'à retrouver le plan de coupe souhaité de l'organe recherché. De plus, dans le cadre de la convention CIFRE, l'implantation d'une telle méthode a ouvert d'autres perspectives. L'étape théorique présentée dans ce travail de thèse est primordiale pour un prétraitement de l'image. A partir de ces résultats, il est envisageable d'aborder une reconstruction 3D de l'environnement anatomique du patient distant dans lequel l'expert navigue. Les capteurs proprioceptifs du bras robotisé donnent une information suffisante sur le positionnement de l'effecteur dans un repère de référence (par exemple le bâti du robot) et nous permettent de référencer la nouvelle image acquise dans l'espace. La caractérisation des divers objets de l'image nous permet alors de mettre en correspondance les interfaces des différentes coupes extraites par notre méthode. Un maillage 3D pourra être appliqué sur chaque ensemble d'interfaces appartenant, *a priori*, au même

## Conclusion

objet. Cet espace 3D reconstruit donnera à l'expert un meilleur outil de diagnostic.

\_ La généralisation de la méthode à d'autres types d'images. Bien que non restreinte dans ce manuscrit aux images échographiques (images synthétiques avec ou sans milieux texturés, image d'horizon...), la méthode proposée ici devrait pouvoir être appliquée dans le cas d'images pour lesquelles les méthodes actuelles ne permettent pas forcément de répondre au problème posé par la segmentation. Comme suggéré en fin de chapitre 4, cette méthode devrait être, par exemple, adaptée à la segmentation d'images naturelles texturées (mais de textures différentes entre chaque objet). Dans ce cas, afin d'éviter la phase d'apprentissage, un prétraitement peut être effectué sur l'image afin d'en extraire les milieux. Nous pourrions alors utiliser l'approche développée par [Bi, 1997] pour détecter les milieux présents dans l'image comme des ensembles de pixels de vecteurs d'attributs similaires (vecteurs de moments par exemple).

\_ L'utilisation de la méthode dans le débruitage d'images. En effet, la méthode permet de retrouver la dimension fractale théorique d'un objet. Cette dimension théorique correspond à la dimension de l'objet que l'on observerait dans une image non bruitée. Une telle affirmation permet donc d'envisager une reconstruction de l'image bruitée en une image non bruitée à l'aide de la caractérisation des divers objets la constituant.



## 6 Table des figures

Figure 1 : Affichage d'une image vue à divers niveaux d'observation (texture avec pixels de couleur blancs et noirs qui s'homogénéisent) .....	48
Figure 2 : Exemple de modélisation, par la logique floue, du concept de « taille » des individus.....	49
Figure 3 : Les 3 premières itérations de la construction d'une des courbes de Von Koch. Chaque segment est ainsi décomposé à l'itération suivante en 4 autres segments (issus de quatre transformations différentes $T_1$ , $T_2$ , $T_3$ et $T_4$ ). La courbe est définie par la transition entre le blanc et le noir.....	50
Figure 4 : Les 3 premières itérations pour une courbe de Minkowski. La courbe est définie par la transition entre le blanc et le noir.....	51
Figure 5 : Indépendance de l'attracteur de l'IFS vis-à-vis du support initial. ....	52
Figure 6 : Mise en évidence de l'invariance d'échelle sur la courbe de Minkowski. Un zoom au niveau de l'interface nous ramène sur une structure similaire à la forme originale. ....	53
Figure 7 : Quelques exemples de fractales naturelles : le chou fleur, les poumons humains et le coquillage de Sierpinski (Cymbolia innexa REEVE).....	53
Figure 8 : Le flocon de Von Koch .....	54
Figure 9 : Notion de points intérieurs ( $P_1$ et $P_3$ ) .....	56
Figure 10 : Évolution de la fonction $F_p$ pour les points $P_1$ , $P_2$ et $P_3$ de la Figure 9 pour $R=10$ . $F$ est ici égale à $F_{p1}$ .....	57
Figure 11 : Image initiale vue à une échelle d'observation $R=0$ .....	58
Figure 12 : Perception à différentes échelles d'observation ( $R = 2, 4, 8$ puis $16$ ). Chaque pixel de l'image interagit ainsi avec les pixels voisins (carré de côté $2R+1$ pixels centré sur le pixel étudié).....	59
Figure 13 : Image et représentation des coefficients de pureté des pixels appartenant à la colonne spécifiée de l'image. Le minimum des $c(P,R)$ de la colonne est de $0,53$ .....	59
Figure 14 : Image synthétique où l'interface est une courbe de Von Koch séparant deux milieux uniformes. ....	62
Figure 15 : Transition (noire) obtenue pour une valeur de $k=0,03$ et $R=5$ à partir de la Figure 14. ....	62
Figure 16 : Transitions obtenues sur l'image de la Figure 13 ( $R=10$ ). ....	62
Figure 17 : Exemples de squelettes obtenus (par ordre d'apparition) sur des milieux séparés par la courbe de Minkowski (Figure 4), l'image de la Figure 13 et les milieux séparés par la courbe de Von Koch (Figure 15). ....	63
Figure 18 : Évolution de la zone de transition entre les milieux blanc et noir de la Figure 11 pour différentes valeurs d'échelle d'observation ( $R = 2, 4, 8$ puis $16$ ; $k = 1-M^R$ ).....	64
Figure 19 : Action du facteur de sensibilité $k$ sur la zone de transition ( $R$ fixé à $8$ ). On voit que plus le facteur de sensibilité $k$ augmente, plus la zone de transition s'épaissit. Le dernier cas, intitulé « sans $k$ », correspond à un cas où $M^R+k \geq 1$ . ....	70

Figure 20 : Approximation des interfaces par squelettisation des diverses zones de transitions représentées à la Figure 19. On voit très nettement qu'une faible valeur de k permet une conservation des propriétés de l'interface. ....	71
Figure 21 : Zones de transition obtenues pour diverses valeurs de R et pour un facteur de sensibilité k à 0,03. ....	71
Figure 22 : Estimation de la longueur de la courbe à l'aide de règles de longueurs différentes. ....	73 -
Figure 23 : Exemple de calcul de la longueur de la courbe de Von Koch à l'aide de règles de dimensions diverses. ....	74
Figure 24 : Évolution du dilaté obtenu par dilatations successives du segment de la matrice A par l'élément structurant B. ....	75
Figure 25 : Dimension fractale obtenue par la méthode des dilatations successives sur le squelette de la transition proposée à gauche : 1,11 pour un rayon de voisinage de 2 ..... 76	76
Figure 26 : Représentation sous forme de voxels d'une image numérique avant interpolation du relief par une surface.....	76
Figure 27 : Approximation de la dimension fractale de la surface en bleu via la méthode des dilatations successives.....	77
Figure 28 : Calcul de la dimension fractale de figures appartenant au domaine Euclidien. Complexité estimée grâce à la méthode des dilatations successives.....	78
Figure 29 : Calcul, via la méthode des dilatations successives, de la complexité de deux courbes fractales connues. La courbe de Von Koch à gauche et la courbe de Minkowski à droite.....	78
Figure 30 : Calcul des dimensions fractales des interfaces obtenues sur différentes images synthétisées (avec R=5 et k=0,03) via la méthode des dilatations successives :.....	79
Figure 31 : Dimension fractale estimée de l'interface entre deux milieux texturés (R=12 et k=0,03).....	80
Figure 32 : Autre exemple d'estimation de la dimension fractale d'une interface entre deux milieux texturés (R=12 et k=0,03).....	80
Figure 33 : Image initiale et l'histogramme des niveaux de gris correspondant.....	82
Figure 34 : Transition obtenue à partir des coefficients de pureté de l'image et extraction des deux milieux de référence. ....	82
Figure 35 : Dimension fractale estimée par la méthode des dilatations successives : 1,12. En rouge figurent les données et en vert la régression linéaire. ....	83
Figure 36 : Approximation de la courbe représentant l'histogramme des niveaux de gris de l'image de gauche par superposition de Gaussiennes. Chacune des deux courbes de Gauss, respectivement de paramètres $(A_1, \mu_1, \sigma_1^2)$ et $(A_2, \mu_2, \sigma_2^2)$ , sont des approximations des deux milieux en présence. ....	84
Figure 37 : Transition (à gauche) et interface (à droite) obtenues sur l'image ultrasonore de la Figure 36 en ne considérant que deux milieux. ....	84
Figure 38 : Dimension fractale approchée de la courbe de la Figure 37 par la méthode des dilatations successives. Dimension observée : 1,52.....	85

Figure 39 : Relation graphique (b) entre la dimension fractale observée de l'interface et le coefficient de pureté de l'image pour différentes valeurs d'échelle d'observation R à partir de l'image représentant la courbe de Von Koch (a).....	91
Figure 40 : Évolution de la dimension fractale de l'interface étudiée en fonction du coefficient de pureté de l'image initiale. Les variations du coefficient de pureté de l'image initiale sont obtenues en faisant varier l'échelle d'observation R. ....	93
Figure 41 : Courbe de Minkowski et graphique représentant l'évolution de la complexité de l'interface en fonction du coefficient de pureté de l'image traitée (fonction de R). La pente de la droite de régression linéaire d'équation $y=ax$ approximant le mieux les points obtenus nous permet d'effectuer une estimation de la dimension théorique : 1,52. ....	94
Figure 42 : Calculs des dimensions fractales et du coefficient de pureté de la courbe de Von Koch à différentes échelles d'observation. Le coefficient directeur de la droite de régression linéaire du type $y=ax$ , correspond à une estimation de la dimension fractale théorique de la courbe de Von Koch soit 1,261 ici.....	94
Figure 43 : Image représentant une transition entre un milieu clair et un milieu sombre.	95
Figure 44 : Régression linéaire de type $y=ax$ sur le nuage de points du graphique $Dim_{obs}=f(T^R)$ .....	96
Figure 45 : Régression linéaire de type $y=ax$ sur le nuage de points du graphique $Dim_{obs}=f(T^R_{Normalisé})$ .....	96
Figure 46 : Estimation de la dimension fractale de l'interface incluse dans la transition représentée en vert sur l'image de gauche. La dimension estimée est de 1,18.....	96
Figure 47 : Exemple d'histogramme des niveaux de gris. La courbe rouge correspond au lissage de l'histogramme par application d'une convolution (filtre de type moyenneur).	98
Figure 48 : Dérivées première et seconde de la courbe lissée Figure 47 avec indication de segmentation. ....	99
Figure 49 : Modélisation d'un chromosome de longueur connue 3k (avec k=4 ici).....	101
Figure 50 : Exemple de mélanges à 4 gaussiennes obtenus pour 3 histogrammes de niveaux de gris différents.....	102
Figure 51 : Exemple de segmentation pour une image à trois milieux.....	103
Figure 52 : Exemple de segmentations obtenues (b) sur une image ultrasonore (a) .....	105
Figure 53 : Image ultrasonore (a) et transitions obtenues en prenant les milieux 2 à 2 (b, c et d) .....	105
Figure 54 : Résultats obtenus par une méthode de segmentation basée sur les contours : l'application du Filtre de Prewitt (gradient).....	106
Figure 55 : Résultats obtenus par une méthode basée sur la croissance de régions (à gauche) et notre méthode (à droite). ....	107
Figure 56 : Segmentation réalisée par un expert sur l'image ultrasonore de la Figure 52.a. ....	108
Figure 57 : Exemple de régions extraites :.....	109
Figure 58 : Exemples de transformations permettant de retrouver un range bloc à partir d'un domaine bloc plus grand dans l'image Lena. ....	112

Figure 59 : Image « Lena » (a) et images obtenues via une compression fractale pour laquelle les tailles des domaines blocs carrés ont été fixées à 4 pixels (b), 8 pixels (c) et 16 pixels (d) de côté. PSNR respectifs de 33,03, 26,81 et 14,28 pour les images b, c et d par rapport à l'image originale .....	113
Figure 60 : Schéma de compression envisagé.....	115
Figure 61 : Signal initial (a) et signal approché (b) par l'IFS défini par les deux transformations suivantes :.....	116
Figure 62 : Évolution de l'erreur moyenne sur l'estimation des moments théoriques à partir des moments calculés sur l'échantillon. Plus l'échantillon est important, plus la précision est grande. ....	117
Figure 63 : Attracteurs des IFS estimés à partir de la courbe (a) de la Figure 61 pour des échantillonnages initiaux de $2^{10}$ (a), $2^{13}$ (b) et $2^{18}$ points (c).....	118
Figure 64 : Estimation, via l'utilisation d'un algorithme génétique, des paramètres de l'IFS à deux transformations (en vert) approximant la courbe initiale (en bleu). ....	118
Figure 65 : Courbe approchée par des IFS respectivement, de gauche à droite, à 2 (a) puis 8 (b) transformations. ....	119
Figure 66 : Approximation d'un signal Brownien par un IFS à 8 transformations.....	119
Figure 67 : Courbe simple approximée par un IFS à pôles. ....	120
Figure 68 : Courbes bleues (en pointillés) approximées par des IFS à pôles : 3 matrices de subdivision et 6 points de contrôle nécessaires (82 paramètres) pour modéliser ces signaux.....	121
Figure 69 : Image initiale à dupliquer $I_0$ et image $I_f$ initialisée par du bruit uniforme (chaque classe de niveau de gris contient le même nombre d'individus). ....	123
Figure 70 : $I_f$ de la Figure 69 modifiée en $I_f^*$ suite à l'égalisation d'histogramme par rapport à $I_0$ .....	123
Figure 71 : Égalisation de l'histogramme de l'image $I_f$ de la Figure 69 par rapport à celui de $I_0$ .....	123
Figure 72 : Voisinage anisotrope et vecteur de données associé.....	124
Figure 73 : Exemple de texture reconstruite correctement par l'algorithme de Li-Yi Wei simple résolution. Les images $a_1$ et $b_1$ correspondent aux textures à dupliquer et les figures $a_2$ et $b_2$ aux résultats de synthèse. ....	124
Figure 74 : Exemple de texture reconstruite de façon incorrecte par l'algorithme de Li-Yi Wei en simple résolution. Les images $a_1$ et $b_1$ correspondent aux textures à dupliquer et les figures $a_2$ et $b_2$ aux résultats de synthèse.....	125
Figure 75 : Exemple de textures reconstruites par l'algorithme de Li-Yi Wei (voisinage anisotrope 9x17). Les images $a_1$ et $b_1$ correspondent aux textures à dupliquer et les images $a_2$ et $b_2$ aux résultats de synthèse.....	125
Figure 76 : Image initiale (a) et interface extraite (b) entre les deux milieux texturés ( $R=12$ et $k=0,03$ ). ....	127
Figure 77 : Approximation de l'interface de la Figure 76b. L'IFS à 29 paramètres proposé est obtenu par la méthode de Levenberg-Marquardt. ....	127

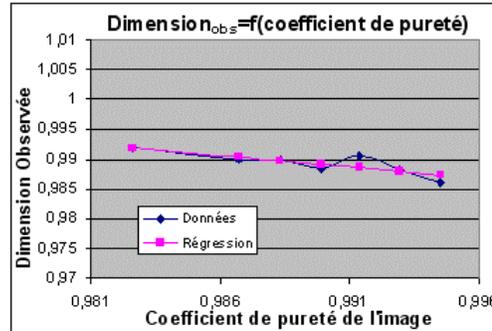
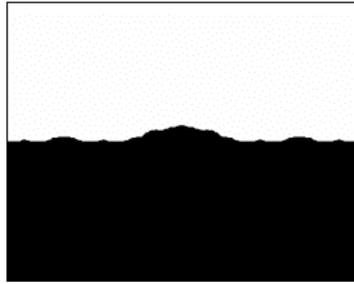
Figure 78 : Textures synthétisées (a2 et b2) à partir d'échantillons (a1 et b1) par application de la méthode de Li-Wei (voisinage de 8x8 pour b1 et 20x20 pour b2). Les échantillons de départ sont constitués chacun de 40x40 pixels. .... 128

Figure 79 : Image reconstruite après décompression..... 128

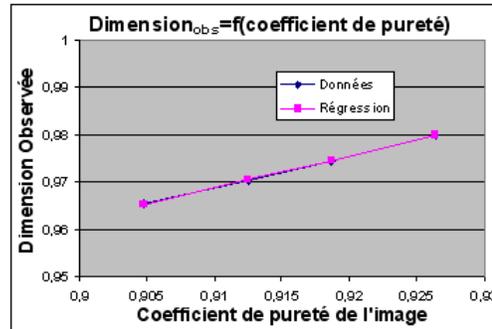
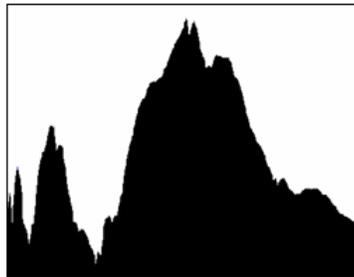
## **7 Annexe**

Exemples de courbes fractales  
évaluées par la méthode proposée

Cette annexe reprend la méthode proposée dans ce manuscrit pour estimer les dimensions théoriques de fractales connues. Cette étape permet de valider l'approche sur des courbes de complexités différentes appartenant à l'intervalle [1, 2]. Les courbes analysées sont étudiées par complexité croissante.



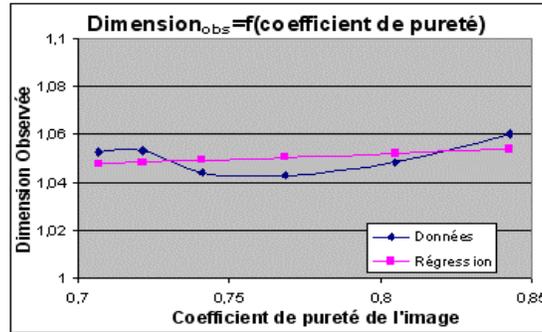
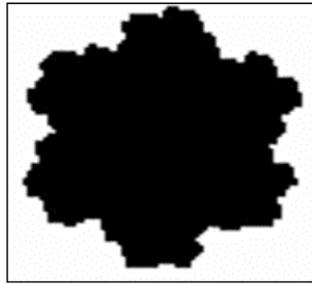
Exemple d'approximation d'une des courbes de Von Koch. La dimension théorique connue de cette courbe est de **1,02**. La régression linéaire trouvée sur le graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = -0,387x + 1,373$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **0,986** dans notre cas.



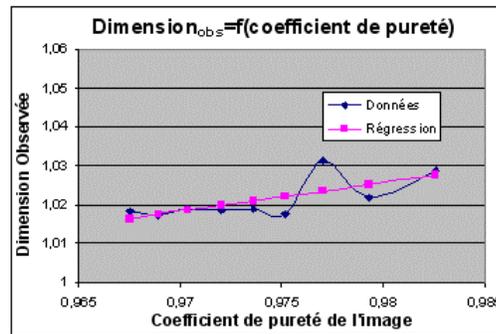
Exemple d'approximation d'une courbe synthétisée par la méthode développée dans [Portefaix, 2004] (section 4.4.2.2.2). Cette fractal a été synthétisée via l'utilisation combinée de deux transformations à 3 paramètres chacune :  $a_1 = -0,75$ ,  $b_1 = -0,63$  et  $c_1 = 0,52$  pour la première ;  $a_2 = -0,28$ ,  $b_2 = 0,15$  et  $c_2 = -0,71$  pour la seconde. La dimension

théorique d'une telle courbe peut être calculée via la relation  $D_{TH} = 1 + \frac{\ln\left(\sum_i a_i\right)}{\ln(2)}$  soit

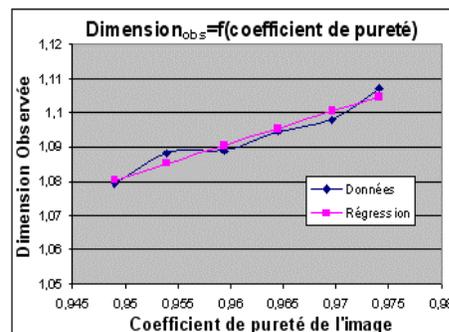
**1,0426** dans ce cas-ci. La régression linéaire trouvée sur le graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 0,673x + 0,356$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,029** dans notre cas.



Exemple d'approximation de la dimension d'une des îles de Gosper (fractal). La dimension théorique connue est de l'ordre de **1,06** pour celle-ci. La régression linéaire trouvée sur le graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 0,041x + 1,019$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,06** dans notre cas.

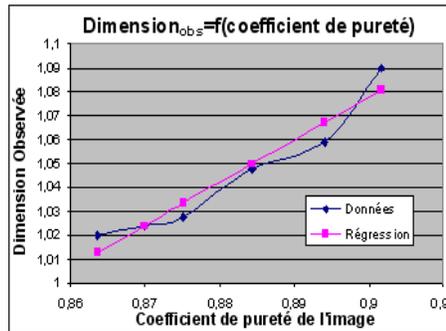
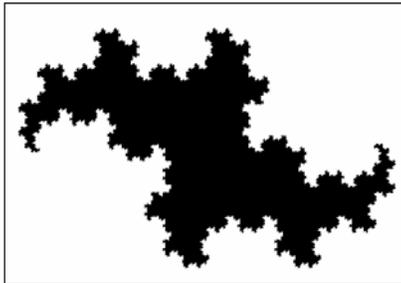


Exemple d'approximation d'une des courbes de Von Koch. Sa dimension théorique connue de cette courbe est de **1,10**. La régression linéaire trouvée sur le graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 0,74x + 0,30$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,04** dans notre cas.

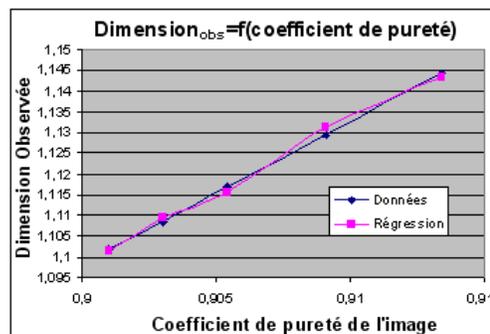
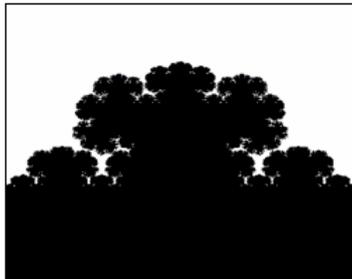


Exemple d'approximation de la dimension fractale théorique de la fractale présentée ci-dessus. La dimension théorique connue est de **1,16**. La régression linéaire trouvée sur le

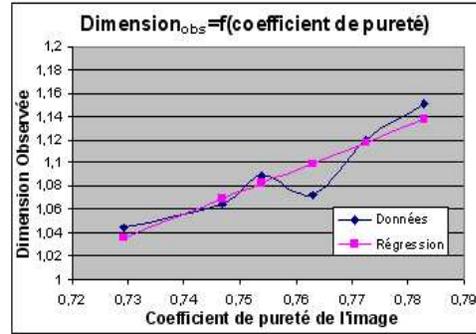
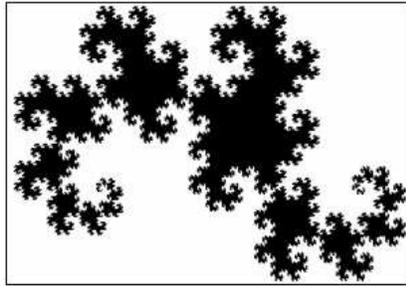
graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 0,975x + 0,155$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,13** dans notre cas.



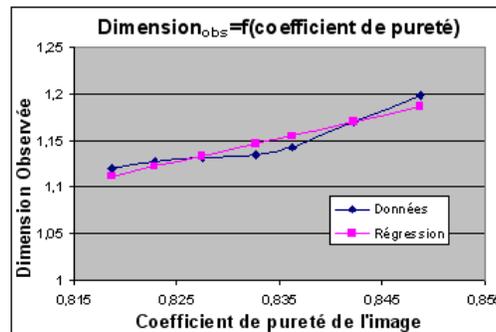
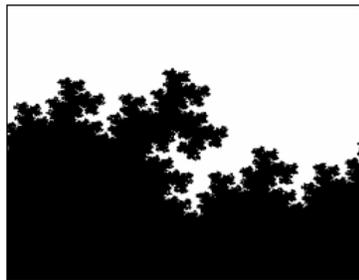
Exemple d'approximation de la dimension fractale théorique du contour de la fractale connue sous le nom de Terdragon. Sa dimension théorique connue est de **1,26**. La régression linéaire trouvée sur le graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 1,78x - 0,53$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,25** dans notre cas.



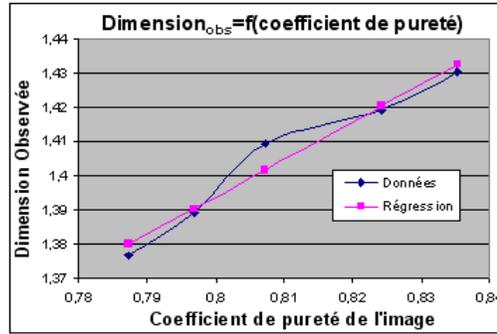
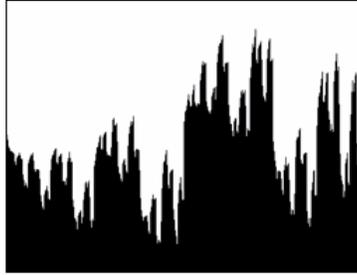
Exemple d'approximation d'une des courbes de Von Koch. Sa dimension théorique connue de cette courbe est de **1,40**. La régression linéaire trouvée sur le graphique  $Dim_{obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 3,40x - 1,965$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,435** dans notre cas.



Exemple d'approximation de la dimension de la courbe fractale du dragon étudiée par Heighway en 1960. Bien que l'objet étant de dimension 2, nous nous intéressons ici à la dimension fractale de son contour. La dimension théorique connue du contour est de l'ordre de **1,52** pour celle-ci. La régression linéaire trouvée sur le graphique  $Dim_{Obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 1,883x - 0,337$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,546** dans notre cas.



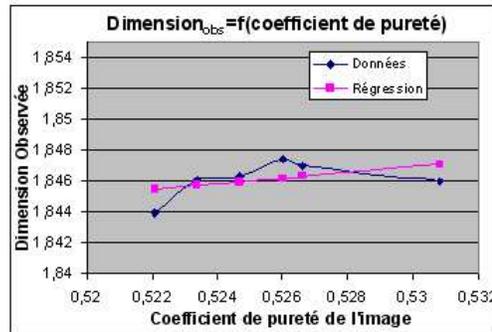
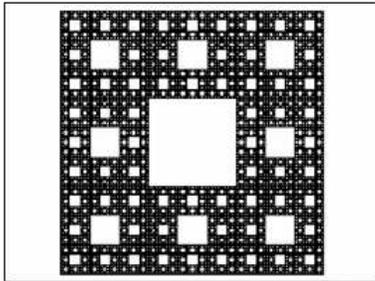
Exemple d'approximation de la dimension fractale théorique de la fractale présentée ci-dessus. La dimension théorique connue est de **1,58**. La régression linéaire trouvée sur le graphique  $Dim_{Obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 2,45x - 0,90$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,56** dans notre cas.



Exemple d'approximation d'une courbe synthétisée par la méthode développée dans [Portefaix, 2004] (section 4.4.2.2.2). Cette fractale a été synthétisée via l'utilisation combinée de deux transformations à 3 paramètres chacune :  $a_1=0,65$ ,  $b_1=-0,1$  et  $c_1=-2,4$  pour la première ;  $a_2=-0,95$ ,  $b_2=-0,8$  et  $c_2=-0,4$  pour la seconde. La dimension théorique

d'une telle courbe peut être calculée via la relation  $D_{TH} = 1 + \frac{\ln\left(\sum_i a_i\right)}{\ln(2)}$  soit **1,62** dans ce

cas-ci. La régression linéaire trouvée sur le graphique  $Dim_{Obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 1,09x + 0,52$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,61** dans notre cas.



Exemple d'approximation de la dimension fractale du tapis de Sierpinski. La dimension théorique connue est de **1,89**. La régression linéaire trouvée sur le graphique  $Dim_{Obs} = f(\text{Coefficient de pureté de l'image})$  est :  $y = 0,18x + 1,75$ . Une approximation de la dimension théorique de cette courbe peut être obtenue dans le cas idéal d'une image non bruitée sans flou donc présentant un coefficient de pureté proche de 1. Une bonne estimation de la dimension théorique peut alors être obtenue en sommant le coefficient directeur et l'ordonnée à l'origine de la droite de régression soit : **1,92** dans notre cas.

## 8 Publications de l'auteur

### ➤ Revue internationale:

- [**A.Capri**, N.Vincent, P.Vieyres, G.Poisson, P. Makris], « *Interfaces areas complexity characterization of echographic images* », Nuclear Instruments and Methods in Physics Research Section A. (à paraître)
- [Ph Arbeille, **A.Capri**, J Ayoub, V Kieffer, G Poisson ], « *Use of a robotic arm to perform remote tele operated abdominal ultrasound* », Am J Roentgenology (in press 2006).
- [P.Arbeille, P.Kerbeci, **A.Capri**, M.Porcher, and J.Boulay], « *Lower Limb Vein Cross Section Changes Measured by Echography inside Spaceflight Stand Test Simulator (LBNP : Lower Body Negative Pressure) and Ground Stand Test* », Biomed 2004 417-809.
- [Arbeille P, **A Capri**, L Pascaud, E Belin de Chantemele, M Porcher, J Boulay],« *Calf vein cross section changes during stand test & LBNP, after 7 days in HDT, in tolerant & non tolerant subjects* », J Gravitational Physiol (in press 2003).
- [Eric Belin de Chantemèle, Ludovic Pascaud, Marc-Antoine Custaud, **Arnaud Capri**, Francis Louisy, Guido Ferretti, Claude Gharib<sup>1</sup> and Philippe Arbeille], « *Calf venous volume during stand-test after a 90-day bed-rest study with or without exercise countermeasure* », J Physiol (London) 2004 561: 611-622.
- [Besnard, Stephane, **Capri, Arnaud**, Philippot, Michel, Herve, Philippe, Porcher, Marie-Annick, Arbeille, Philippe], «*Vascular Distribution of an Ultrasound Contrast Agent Used to Simulate Decompression Bubbles*, Aviation, Space, and Environmental Medicine, Vol. 77, No. 8. (August 2006), pp. 846-851.

### ➤ Congrès nationaux et internationaux avec comité de lecture :

- [**A.Capri**, N.Vincent, P.Vieyres, G.Poisson, P. Makris], « *Image complexity evaluation from pixel purity coefficient study* », Information Processing and Management of Uncertainty in Knowledge-Based Systems 2006, Paris
- [**A.Capri**, N.Vincent, P.Vieyres, G.Poisson, P. Makris],« *Interfaces areas complexity characterization of echographic images* », Imaging Technologies in Biomedical Sciences 2005, Milos, Grece.
- [P. Makris, **A. Capri**, N.Vincent], « *Une approche floue pour le calcul de la dimension fractale* », Logique Floue et Applications 2003, Tours.
- [Sotos Voskarides, Sotiris Avgousti, Marios Kassinopoulos, George Florides, Costas Pattichis, Chrysa Tziakouri, Marios Hadjinicolaou, **Arnaud Capri**, Pierre Vieyres, Gerard Poisson, Arbeille Philippe, Natalie Smith-Guerin, Aïcha Fonte, Gilles Mourioux, Laurence Josserand, Cyril Novales], « *Marte project : tele-echography between Kyperounta and Nicosia (Cyprus)* », 9th IFAC Symposium on Automated Systems Based on Human Skill And Knowledge, Nancy 22-24 May 2006.
- [**A. Capri**, P. Kerbeci, L. Pascaud, and Ph. Arbeille], « *Assessment of the Calf Vein Cross Section Change during Stand-Test after a 90 Day Bed Rest by Echography* ». 25th Annual International Gravitational Physiology Meeting ; Moscow, Russia ; 6 - 11 June 2004.

[Arbeille, P.; Audebert, P.; **Capri, A.**; Kerbeci, P.; Pascaud, L], « *Calf Tissue Liquid Stowage and Vein Size in Orthostatic Tests after a 90-day Head Down Bed Rest* ». ESA / ISGP Life Science Symposium 2005. 26 June - 1 July 2005 Cologne, Germany.

➤ Congrès à diffusion restreinte :

[**A.Capri**, N.Vincent, P.Vieyres, G.Poisson, P. Makris], « *Apports des techniques floues et fractales pour la compression d'images échographiques* », JJC 2005, LVR, Châteauroux.

[**A.Capri**, N.Vincent, P.Vieyres], « *Reconstruction 3D par imagerie ultrasonore à l'aide d'un robot léger télé-opéré pour l'assistance au diagnostic* », JJC 2006, LVR, Polytech Orléans.

➤ Poster :

[**A.Capri**, N.Vincent, P.Vieyres, G.Poisson, P. Makris, L.Urbain, A.Arbeille], « *De l'échographie 2D robotisée à l'échographie 3D* », Pôle Capteur 2005, Bourges.

## 9 Références

- [Adams et Bischof, 1994] R. Adams, et L. Bischof, “Seeded region growing”, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 16, no. 6, 1994.
- [Albouy et al., 2006] Albouy, B., Koenig, E., Treuillet, S., Lucas, Y., “Accurate 3D Structure Measurements from Two Uncalibrated Views”, ACIVS06 (1111-1121).
- [Arbelaez, 2005] Pablo Andrés Arbeláez Escalente, “Une approche métrique pour la segmentation d’images”, Thèse de Doctorat, Université Paris Dauphine, novembre 2005.
- [Argenty et al., 1990] F. Argenty, L. Alparone, and G. Benelli, “Fast Algorithms for Texture Analysis using Co-occurrence Matrices,” in IEE Proceedings, Part F: Radar and Signal Processing, vol. 137(6), pp. 443-448, 1990.
- [Asada et Brady, 1986] H. Asada and M. Brady, “The curvature primal sketch,” IEEE Trans. Pattern Anal. Machine Intell., vol. 8, pp. 2–14, 1986.
- [Bachnou, 1999] Bachnou, A. (1999) - Modélisation des contours fermés : « AN-MORPH » outil mis au point pour maîtriser les composantes des profils latéraux des ostracodes. Perspective d’application systématique. Geobios, 32 (5) : 733-742.
- [Baddeley, 1992] A. J. Baddeley. “An Error metric for binary images”. Robust Computer Vision, pages 59–78, 1992.
- [Bangham et al., 1996] J. A. Bangham, P. Chardaire, C. J. Pye, and P. D. Ling, “Multiscale nonlinear decomposition: the sieve decomposition theorem,” IEEE Trans. Pattern Anal. Machine Intell., vol. 18, pp. 529–538, 1996.
- [Bao et al., 2005] Bao, P., Zhang, L. et Wu, X. (2005). « Canny edge detection enhancement by scale multiplication”. IEEE Trans. on Pattern Analysis and Machine Intelligence, 27(9):1485–1490.
- [Barlaud et Labit, 2002] Barlaud (Michel) et Labit (Claude). « Compression codage des images et des vidéos » Paris, Hermès, Janvier 2002.
- [Barnsley, 1986] M. F. Barnsley. “Fractal functions an interpolation”. Constructive Approximation, 2 :303\_329, 1986.
- [Barnsley, 1988] M. F. Barnsley. “Fractals Everywhere. Academic Press”, New York, 1988.
- [Barnsley et al., 1989] M. F. Barnsley, J. Elton, D. Hardin, et P. Massopust. “Hidden variable fractal interpolation”. SIAM Journal of Math Analysis, 20(5) :1218\_1242, 1989.
- [Barnsley et Jacquin, 1988] M. Barnsley et A. Jacquin. « Application of recurrent iterated function system to images”. SPIE Visual Communications and Image Processing, 1001:122–131, 1988.
- [Barry et Goldman, 1988] Barry, P., Goldman, R., 1988. “Recursive proof of Boehm’s knot insertion technique”. Computer-Aided Design 20 (4), 181–182.
- [Barthel et Voye, 1994] K.U. Barthel et T. Voye. « Adaptive fractal image coding in the frequency domain”. In Proc. Int. Workshop on Image Processing : Theory, Methodology, Systems and Applications, volume XLV, pages 33\_38, Budapest, Juin 1994.
- [Basseville, 1989] M. Basseville. “Distance measures for signal processing and pattern recognition”. Signal processing, 18 (4) : 349–369, 1989.
- [Bhattacharya, 1967] C.G. Bhattacharya. “A simple method of resolution of a distribution into Gaussian components”, Biometrics, Vol.23, p115-135, 1967

- [Besançon, 1988] Besançon, J. E. (1988). « Vision par ordinateur en deux et trois dimensions ». Paris: Eyrolles.
- [Bi, 1997] Duyan BI, “Segmentation d’images basées sur les statistiques de rangs des niveaux de gris”, Thèse de Doctorat, Ecole d’Ingénieurs en Informatique pour l’Industrie de l’Université de Tours, janvier 1997.
- [Blum, 1964] Harry Blum. « A transformation for extracting new descriptors of shape ». In Symposium on Models for the Perception of Speech and Visual Form, M.I.T Press, p.139-146, 1964.
- [Borsotti et al., 1998] M. Borsotti, P. Campadelli, et R. Schettini. « Quantitative evaluation of color image segmentation results”. Pattern Recognition Letters, 19 : 741–747, 1998.
- [Bovik et al., 1990] A. Bovik, M. Clarke, and W. Geisler, “Multichannel Texture Analysis using Localized Spatial Filters”, Pattern Analysis and Machine Intelligence, vol. 12, pp. 55-73, 1990.
- [Bowyer, 2001] K. Bowyer. “Edge Detector Evaluation Using Empirical ROC Curves”. Computer Vision and Understanding, 84 : 77–103, 2001. Breen, 1996
- [Brodatz, 1966] P. Brodatz. Textures, a photographic album for artists and designers. Dover, New York, 1966.
- [Canny, 1986] J. Canny, “A computational approach to edge detection”, IEEE Trans. On Pattern Analysis and Machine Intelligence, vol. 8, n°6, p. 679-698, novembre 1986.
- [Chabrier, 2005] Sébastien Chabrier, « Contribution à l’évaluation de performances en segmentation d’images. », Thèse de Doctorat, à l’Université d’Orléans, 2005
- [Chang et Kuo, 1993] T. Chang and C. J. Kuo, “Texture analysis and classification with tree structured wavelet transform”, IEEE Trans. Image Process., vol. 2, no. 4, pp. 429–441, Apr. 1993.
- [Chassery et Montonvert, 1991] J.M. Chassery, Montonvert A., « Géométrie discrète en analyse d’image »
- [Chassery et Melkemi, 1991] J.M. Chassery et M. Melkemi. « Diagramme de Voronoï appliqué à la segmentation d’images et à la détection d’événements en imagerie multi-sources ». Traitement du signal, 8(3) :155–164, 1991.
- [Chaudhuri et al., 1993] B. Chaudhuri, N. Sarkar, and P. Kundu, « Improved Fractal Geometry Based Texture Segmentation Technique », IEE Proceedings, Part E, vol. 140, pp. 233-241, 1993.
- [Chellappa et Jain, 1993] R. Chellappa, et A.K Jain, Editors, 1993. « Markov Random Fields: Theory and Application”, Academic Press, San Diego.
- [Chen et al., 2002] Shin-Si Chen, Chang-Biau Yang, and Kuo-Si Huang, “Fractal image compression based on intrablock variance distribution and vector quantization”, Optical Engineering, November 2002
- [Chuang et Kuo, 1996] G. C.-H. Chuang and C.-C. J. Kuo, “Wavelet descriptor of planar curves: Theory and applications,” IEEE Trans. Image Processing, vol. 5, pp. 56–70, 1996.
- [Chui, 1992] Chui, C., 1992. “An Introduction to Wavelets”. Academic Press, Boston.
- [Chung et al., 1994] P.C. Chung, C.T. Tsai, E.L. Chen, Y.N. Sun, “Polygonal approximation using a competitive Hopfield neural network”, Pattern Recognition 27:1505-1512, 1994.
- [Cocquerez et Devars, 1985] J-P. Cocquerez and J. Devars. « Détection de contours dans les images aériennes: Nouveaux opérateurs ». Traitement du signal, 2(1) : 45-65, 1985.

- [Cocquerez et Philipp, 1995] J.-P. Cocquerez et S. Philipp. « Analyse d'Images : filtrage et segmentation ». Masson, 1995
- [Cohen, 1997] L. Cohen, « Modèles déformables », conférence invitée École Thématiques ISIS, Marly-le-Roy, 1997
- [Coquin et al., 1997] D. Coquin, P. Bolon, et Y. Chehadeh. « Évaluation quantitative d'images filtrées ». GRETSI97, 2 : 1351–1354, 1997.
- [Coquin et al., 2002] D. Coquin, P. Bolon, and B. Ionescu. « Dissimilarity measures in color spaces ». In 16th ICPR, volume 1, 2002.
- [Coquin et Bolon, 2001] D. Coquin et Ph. Bolon. “Application of Baddeley’s distance to dissimilarity measurement between gray scale images”. *Pattern Recognition Letters*, 22(14) : 1483–1502, 2001.
- [Correia et Pereira, 2000] P. Correia et F. Pereira. « Objective Evaluation of Relative Segmentation Quality ». *International Conference on Image Processing*, pages 308–311, September 2000.
- [Cross et Jain, 1983] G. Cross and A. Jain, “Markov Random Field Texture Models,” *Pattern Analysis and Machine Intelligence*, vol. 5, pp. 25-39, 1983.
- [Davoine, 1995] Franck Davoine. « Compression d'images par fractales basée sur la triangulation de Delaunay ». Thèse de Doctorat, Institut National Polytechnique de Grenoble, Laboratoire TIMC - Institut IMAG, décembre 1995.
- [Delgorge, 2005] Delgorge, « Proposition et évaluation de techniques de compression d'images ultrasonores dans le cadre d'une télé-échographie robotisée. », Thèse de Doctorat, Université d'Orléans, décembre 2005.
- [Delingette et Montagnat, 2001] Delingette, H. et Montagnat, J. (2001). “Shape and topology constraints on parametric active contours” *Computer Vision and Image Understanding*, 83(2):359–369.
- [Deriche, 1987] R. Deriche, “Using Canny's criteria to derive a recursively implemented optimal edge detector”, *International Journal of Computer Vision*, p. 167-187, 1987.
- [Dougherty et al., 1989] E. Dougherty, E. Kraus, and J. Pelz, “Image Segmentation by Local Morphological Granulometries,” in *Proceedings of IGARSS'89 and Canadian Symposium on Remote Sensing*, pp. 1220-1223, 1989.
- [Duda et al., 2001] Duda, R. O., Hart, P. E. et Stork, D. G. (2001). *Pattern Classification*. Wiley Interscience.
- [Dudek et Tsotos, 1997] G. Dudek and J. K. Tsotsos, “Shape representation and recognition from multiscale curvature,” *Comput. Vision Image Understand.*, vol. 68, pp.170–189, 1997.
- [Dufour et al., 2005] Dufour, A., Shinin, V., Tajbakhsh, S., Guillen-Aghion, N., Olivo-Marin, J.-C. et Zimmer, C. (2005). “Segmenting and tracking fluorescent cells in dynamic 3-D microscopy with coupled active surfaces”. *IEEE Trans. on Image Processing*, 14(9):1396–1410.
- [Dupont et al, 2003] Dupont Florent, Gilles Benjamin, Baskurt Atila, « Transmission progressive d'objets 3D basée sur le calcul d'axe médian », *Colloque CORESA'03*, Lyon, France, 2003.
- [Fisher et al., 1992] Fisher, Y., Jacobs, E. W., Boss, R. D., “Fractal image compression using iterated transforms, in: *Image and Text Compression*”, J. A. Storer (ed.), Klumer Academic Publishers, Boston, pp. 35-61, 1992.
- [Fisher, 1994] Fisher, Y., “Fractal Image Compression – Theory and Applications to Digital Images”, Springer-Verlag, New York, 1994.

- [Fisher, 1995a] Y. Fisher. "Fractal Image Compression : Theory and Application". Springer-Verlag, New York, 1995.
- [Fisher, 1995b] Y. Fisher, "Fractal Image Compression with Quadrees," pages 55-77. "In Fractal Image Compression: Theory and Application to Digital Images", New York, 1995.
- [Fisher, 1998] Y. Fisher. "Fractal Image Encoding and Analysis". Springer-Verlag, New York, 1998.
- [Forsey et Bartels, 1988] Forsey, D., Bartels, R., 1988. "Hierarchical B-spline refinement". In: Proceedings of SIGGRAPH 1988. ACM, pp. 205–212.
- [Galloway, 1975] M. Galloway, "Texture Classification using Grey Level Run Length," Computer Graphics and Image Processing, vol. 4, pp. 172-179, 1975.
- [Gersho et Gray, 1993] A. Gersho et R.M. Gray. "Vector quantization and Signal compression". Kluwer Academic Publishers, 1993.
- [Ghosh et al., 2004] S. K. Ghosh, J. Mukherjee, et P. P. Das. « Fractal image compression: a randomized approach ». Pattern Recognition Letters, In Press, Corrected Proof, 2004.
- [Glasbey, 1993] Glasbey, "An analysis of histogram-based thresholding algorithms". CVCGIP : Graphical Models and Image Processing, 55(6) : 532-537, 1993
- [Glory et al., 2006] Glory, E., Meas-Yedid, V., Pinset, C., Olivo-Marin, J.-C. et Stamon, G. (2006). "Évaluation automatique de la qualité de segmentations couleur en imagerie cytologique ». In Conférence de Reconnaissance des Formes et Intelligence Artificielle.
- [Gonzales et Wintz, 1987] R.C. Gonzales and P. Wintz: "Digital Image Processing", Addison-Wesley P.C. Massachussets, 1977. Seconde édition 1987.
- [Gourdon, 2000] A. Gourdon. « Développement et commande d'un porte-sonde robotisée : application à la télémédecine ». Thèse de Doctorat, Université d'Orléans, décembre 2000.
- [Guérin, 2002] Eric Guérin, « Approximation fractale de courbes et de surfaces », Thèse de Doctorat, Université Claude Bernard – Lyon 1, décembre 2002.
- [Guérin et al., 2002] E. Guérin, E. Tosan, et A. Baskurt. "Modeling et Approximation of Fractal Surfaces with projected IFS attractors". Emergent Nature, pages 203\_214, 2002.
- [Guillois, 1996] J.P. Guillois. « Techniques de compression d'images ». computer collection, hermes edition, 1996.
- [Gupta et al., 1993] Gupta, S. Chaudhury, G. Parthasarathy, "A new approach for aggregating edge points into line segments", Pattern Recognition 26:1069-1086, 1993
- [Han et Kim, 2002] J. H. Han et T. Y. Kim. "Ambiguity distance : an edge evaluation measure using fuzziness of edges". Fuzzy Sets and Systems, 126 : 311–324, 2002.
- [Haralick et al., 1973] R. Haralick, K. Shanmugan, et I. Dinstein. "Textual features for image classification". IEEE Transactions on system, Man, and Cybernetics, SMC-3 (6) : 610–621, 1973
- [Heath et al., 1996] Mike Heath, Sudeep Sarkar, Thomas Sanocki, et Kevin Bowyer. "Comparison of Edge Detectors : A Methodology and Initial Study. Computer vision and image understanding, 69(1)" : 38–54, january 1996.
- [Heipke et al., 1997] C. Heipke, H. Mayer, C. Wiedemann, et O. Jamet. "Evaluation of automatic road extraction". International Archives of Photogrammetry and Remote Sensing, Vol. 32 Part 3-2W3 : 47–56, 1997.
- [Holland, 1975] J. Holland "Adaptation in Natural and Artificial Systems", MIT Press, 1975.

- [Horng et Li, 2002] J.H. Horng, J.T. Li, "An automatic and efficient dynamic programming algorithm for polygonal approximation of digital curves", *Pattern Recognition Lett.* 23:171-182, 2002
- [Hu, 2002] Hu, H. Yan, "Polygonal approximation of digital curves based on the principles of perceptual organization", *Pattern Recognition* 30:701-718, 2002.
- [Huang et al., 2005] Qi-Xing Huang, Shi-Min Hu, Ralph R. Martin: "Fast degree elevation and knot insertion for B-spline curves. *Computer Aided Geometric Design* 2005: 183-197
- [Huang et Sun, 1999] S.C. Huang, Y.N. Sun, "Polygonal approximation using genetic algorithm", *Pattern Recognition* 32, 1409-1420, 1999.
- [Huet et Philipp, 1998] F. Huet and S. Philipp. Fusion of images interpreted by a new fuzzy classifier. *Pattern Analysis and Applications*, 1:230–247, 1998.
- [Huffmann, 1952] D.A. Huffmann. A method for the construction of minimum redundancy codes. *Proceedings of the Institute of Radio Engineers*, pages 1098–1101, 1952.
- [Hürtgen et al., 1994] B. Hürtgen, P. Mols, et S.F. Simon. Fractal transform coding of color images. In *Visual Communications and Image Processing '94*, éditeur Aggelos K. Katsaggelos, 2308 de SPIE Proceedings, pages 1683\_1691, Chicago, IL, USA, Juillet 1994.
- [Hutchinson, 1981] Hutchinson J., *Fractals and self-similarity*, Indiana University Journal of Mathematics, 30:713-747, 1981.
- [Jackway et Deriche, 1996] P. T. Jackway and M. Deriche, "Scale-space properties of the multiscale morphological dilation-erosion," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 18, pp. 38–51, 1996.
- [Jain et Dudes, 1988] A. Jain and R. Dubes, *Algorithms for Clustering Data*. Prentice Hall, 1988
- [Jalba et al., 2004] A. C. Jalba, M. H. F. Wilkinson, and J. B. T. M. Roerdink, "Morphological hat-transform scale spaces and their use in pattern classification," *Pattern Recognition*, vol. 37, pp. 901–915, 2004.
- [Jalba et al., 2006] A.C. Jalba, M.H.F. Wilkinson and J.B.T.M. Roerdink. Shape representation and recognition through morphological curvature scale spaces. *IEEE Trans. Image processing* 15 (2), pp. 331-341, 2006.
- [Jang et Chin, 1998] B. K. Jang and R. T. Chin, "Morphological scale space for 2d shape smoothing," *Comput. Vision Image Understand.*, vol. 70, pp. 121–141, 1998.
- [Jones, 2001] H. Jones. Iterated function systems for object generation and rendering. *International Journal of Bifurcation and Chaos*, 11(2) :259\_289, 2001.
- [Kapur et al., 1985] J.N. Kapur, P. K. Sahoo and A. K.C. Wong . A new method for gray-level picture thresholding using the entropy of histogram *CVGIP* 29 pp.273-285 1985
- [Kass et al., 1987] Kass, M., Witkin, A. et Terzopoulos, D. (1987). Snakes : active contour models. *International Journal of Computer Vision*, 1(4): 321–331.
- [Kazinnik et Elber, 1997] Kazinnik, R., Elber, G., 1997. Orthogonal decomposition of non-uniform B-spline spaces using wavelets. In: *Proceedings of EUROGRAPHICS 1997*, Computer Graphics Forum, pp. 27–38.
- [Kimia et Siddiqi, 1996] B. Kimia and K. Siddiqi, "Geometric heat equation and nonlinear diffusion of shapes and images," *Comput. Vision Image Understand.*, vol. 64, pp. 305–322, 1996.
- [Kitchen et Rosenfeld, 1981] L. Kitchen et A. Rosenfeld. "Edge evaluation using local edge coherence". *IEEE Trans. Syst., Man, Cybern.*, Vol. SMC-11, pp. 597-605, 1981

- [Kjell et Wang, 1991] P. Kjell and P. Wang, "Noise-tolerant Texture Classification and Image Segmentation," in *Intelligent Robots and Computer Vision*, pp. 553-560, 1991.
- [Laurent-Gengoux et Mekhilef, 1993] P. Laurent-Gengoux, and M. Mekhilef, "Optimization of a NURBS representation", *Computer Aided Design*, pp. 699-710, vol 25, No.11, 1993.
- [Laws, 1980] K. Laws, *Textured Image Segmentation*. PhD thesis, University of Southern California, 1980.
- [Letournel, 2002] V. Letournel. *Contribution à l'évaluation d'algorithmes de traitement d'images*. Thèse de Doctorat, ENST Paris, décembre 2002.
- [Levenberg, 1944] Levenberg, K. "A Method for the Solution of Certain Problems in Least Squares." *Quart. Appl. Math.* 2, 164-168, 1944.
- [Levine et Nazif, 1985] M. D. Levine et Ahmed M. Nazif. *Dynamic Measurement of Computer Generated Image Segmentations*. *IEEE Transaction on Pattern Analysis and Machine intelligence*, PAMI-7(2) : 155–164, March 85.
- [Lévy-Véhel et al., 1994] Jacques LEVY VEHEL, Khalid DAOUDI and Evelyne LUTTON "Fractal Modelling of Speech Signals" *Fractals*. Vol. 2. Num. 3. 1994. pp.379-382
- [Leymarie et Levine, 1989] F. Leymarie and M. D. Levine, "Shape features using curvature morphology," in *Proceedings SPIE, ser. Visual Communications and Image Processing IV*, vol. 1199, 1989, pp. 390–401.
- [Lezoray, 2000] Lezoray, O. (2000). *Segmentation d'images par morphologie mathématique et classification de données par réseaux de neurones : Application à la classification de cellules en cytologie des séreuses*. These de doctorat, Université de Caen.
- [Li et al., 2005a] Weishi Li, Shuhong Xu, Gang Zhao, Li Ping Goh: Adaptive knot placement in B-spline curve approximation. *Computer-Aided Design* 37(8): 791-797 (2005)
- [Li et al., 2005b] Denggao. Li, K. Qin, H. Sun: Curve modeling with constrained B-spline wavelets. *Computer Aided Geometric Design* 2005: 45-56
- [Li et Kuo, 1999] J. Li et C.-C.J. Kuo. Image compression with a hybrid wavelet-fractal coder. *IEEE Transactions on Image Processing*, 8(6) :868\_874, 1999.
- [Liu et Yang, 1994] J. Liu et Y.-H. Yang. *Multiresolution Color Image Segmentation*. *IEEE Trans on PAMI*, 16(7) : 689–700, 1994.
- [Lu et Yew, 1994] Lu (G.) et Yew (T.-L.). – Image compression using quadtree partitioned iterated function systems. *Electronic Letters*, vol. 30, No 1, 1994, pp. 23–24.
- [Lyche et al., 2001] Lyche, T., Mørken, K., Quak, E., 2001. *Theory and Algorithms for Non-Uniform SplineWavelets*. Cambridge University Press.
- [Lyche et Mørken, 1987] Lyche, T., Mørken, K., 1987. Knot removal for parametric B-spline curves and surfaces. *Computer Aided Geometric Design* 4 (3), 217–230.
- [Maes, 1998] Maes, F.: *Segmentation and Registration of Multimodal Images: From Theory, Implementation and Validation to a Useful Tool in Clinical Practice*. PhD thesis, Katholieke Universiteit Leuven, Leuven, Belgium (1998)
- [Maitre, 2003] Henri maitre, "le traitement d'images", Hermès, 2003
- [Malladi et al., 1995] R . Malladi, J. A . Sethian and B . C. Vemuri . "Shape Modeling with Front Propagation : A Level Set Approach", *IEEE-PA MI*, 17(2) :158-175, February 1995 .
- [Mallat, 1989] S. Mallat, "A Theory of Multiresolution Signal Decomposition: The Wavelet Representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, pp. 674{693, 1989.

- [Mandelbrot, 1982] B. B. Mandelbrot. *The Fractal Geometry of Nature*. W.H. Freeman and Co, San Francisco, 1982.
- [Manjunath et Chellappa, 1991] B. Manjunath and R. Chellappa, "Unsupervised Texture Segmentation using Markov Random Field Models," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13(5), pp. 478-482, 1991.
- [Mardia et Hainsworth, 1988] K.V. Mardia and T.J.Hainsworth, « A spatial thresholding method for image segmentation » *IEEE Trans. PAMI*, Vol.10, p919-927, 1988
- [Marji et Siy, 2003] M. Marji, P. Siy, "A new algorithm for dominant points detection and polygonization of digital curves", *Pattern Recognition* 36:2239-2251, 2003.
- [Marr, 1976] Marr, D. (1976). Early processing of visual information. In *Philosophical Transactions of the Royal Society of London*, volume 275 of B (pp. 483-524).
- [Marr, 1982] Marr, D. (1982). *Vision : A Computational Investigation into the Human Representation and Processing of Visual Information*. San Francisco : W.H. Freeman and Co.
- [Marr et Hildreth, 1980] D.Marr and E.Hildreth, « Theory of edge detection », In *Proc. Roy. Soc. London*, pP187-207, 1980.
- [Marr et Nishihara, 1978] Marr, D. & Nishihara, H. K. (1978). Representation and recognition of the spatial organization of three dimensional shapes. In *Proceedings of the Royal Society of London*, volume 207 of B (pp. 187-216).
- [Martin et al., 2004] D. Martin, C. Fowlkes, D. Tal, and J. Malik. Learning to detect natural image boundaries using local brightness, color and texture cues. *IEEE Trans. On PAMI*, 26(5):530-549, 2004.
- [Mazel et Hayes, 1992] D. S. Mazel et M. H. Hayes. Using iterated function systems to model discrete sequences. *IEEE Transactions on Signal Processing*, 40(7) :1724\_1734, 1992.
- [Mitra et al., 1998] S.K. Mitra, C.A. Murthy, et M.K. Kundu. Technique for fractal image compression using genetic algorithm. *IEEE Transactions on Image Processing*, 7(4) :586\_593, Avril 1998.
- [Mitra et Sarbadhikari, 1997] Suman K. Mitra et S. N. Sarbadhikari. Iterative function system and genetic algorithm-based eeg compression. *Medical Engineering and Physics*, 19(7):605\_617, 1997.
- [Mokhtarian et Mackworth, 1986] F. Mokhtarian A. k. Mackworth, "Scale-Based Description and recognition of Planar Curves and Two-Dimensional Shapes", *IEEE PAMI*, Vol. 8, pp. 34-43, 1986.
- [Nikolaidis et Pitas, 2001] N. Nikolaidis and I. Pitas, *3-D Image Processing Algorithms*. John Wiley and Sons Inc., 2001.
- [Odet et al., 2002] C. Odet, B. Belaroussi, et H. Benoit-Cattin. Scalable Discrepancy Measures for Segmentation Evaluation. *ICIP*, 1 : 785-788, septembre 2002.
- [Oien et Narstad, 1995] G. E. Oien and G. Narstad, Fractal Compression of ECG Signals, in Y. Fisher (ed.), *Conf. Proc. NATO ASI Fractal Image Encoding and Analysis*, Trondheim, July 1995
- [Osher et Sethian, 1988] Osher, S. et Sethian, J. A. (1988). Front propagating with curvature dependent speed : algorithm based on hamilton-jacobi formulations. *Journal of Computational Physics*, 79:12-49.
- [Otsu, 1979] Otsu, N. (1979). Threshold selection method from gray-level histograms. *IEEE Trans. System, Man and Cybernetics*, 9(1):62-66.

- [Pal et Pal, 1991] N.R.Pal and S.K. Pal, « Image model, Poisson distribution and object extraction », *Int. J. Pattern Recognition Artif. Intell.* N°5, p459-483, 1991.
- [Pavlidis et Horowitz, 1974] T. Pavlidis, S.L. Horowitz, "Segmentation of plane curves", *IEEE Transaction on Computers* 23:860-870, 1974.
- [Pavlidis et Liow, 1990] T. Pavlidis and Y.-T. Liow. Integrating region growing and edge detection. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 12(3):225--233, 1990.
- [Pentland, 1984] Pentland, A., "Fractal-based description of natural scenes," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-9, pp. 661-674, 1984.
- [Philipp-Foliguet et Guigues, 2005a] S. Philipp-Foliguet et L. Guigues. « Evaluation de la segmentation d'images : état de l'art, nouveaux indices et comparaison »
- [Philipp-Foliguet et Guigues, 2005b] S. Philipp-Foliguet et L. Guigues. Critères multi-échelles d'évaluation de la segmentation. *GRETSI*, 2005.
- [Picard, 1991] R. W. Picard, *Texture Modelling: Temperature Effects on Markov/Gibbs Random Fields*. PhD thesis, Massachusetts Institute of Technology, 1991.
- [Portefaix, 2004] Portefaix, Modélisation des signaux et des images par les attracteurs fractals de systèmes de fonctions itérées (IFS), Thèse de doctorat, Université d'Angers, 2004
- [Portefaix et al., 2003] C. Portefaix, C. Cavaro-Ménard, et F. Chapeau-Blondeau. Modelling of fractal images with iterated function systems : Moment matching, continuity of attractors. In *Proceedings 3rd International Symposium on Physics in Signal and Image Processing*, pages 113\_116, Grenoble, France, 29\_31 Jan. 2003.
- [Pratt, 2001] William K. Pratt, "Digital Image Processing ", Wiley-Interscience, 2001. Third Edition.
- [Pratt et al., 1978] W. Pratt, O. D. Faugeras, et A. Gagalowicz. Visual discrimination of stochastic texture fields. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(11) : 796–804, 1978.
- [Puzicha et al., 1996] J. Puzicha, T. Hofmann, and J. Buhmann, "Unsupervised Texture Segmentation on the Basis of Scale Space Features." 1996
- [Raghu et Yegnanarayana, 1996] Raghu, P.P., Yegnanarayana, B., 1996. Segmentation of Gabor filtered textures using deterministic relaxation. *IEEE Trans. Image Process.* 5 (12), 1625–1636.
- [Randrianarivony et Brunnett, 2002] M. Randrianarivony, G. Brunnett, Approximation by NURBS curves with free Knots, *Proc. Vision, Modeling and Visualization 2002*, Akademischer Verlagsgesellschaft, 195-201, ISBN: 3-89838-034-3, 2002.
- [Razdan, 1999] Razdan A. Knot Placement for B-spline curve approximation. Tempe, AZ: Arizona State University; 1999
- [Reed et Wechsler, 1990] Reed and Wechsler, "Segmentation of Textured Images and Gestalt Organization Using Spatial/Spatial-Frequency Representations," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-12, pp. 1-12, 1990.
- [Reusens, 1994] E. Reusens. Overlapped Adaptive Partitioning for Image Coding Based on the Theory of Iterated Functions Systems. In *Proceedings ICASSP-94 (IEEE International Conference on Acoustics, Speech and Signal Processing)*, volume 5, pages 569\_572, Adelaide, Australia, 1994
- [Ridler et Calvard, 1978] Ridler, T. et Calvard, S. (1978). Picture thresholding using an iterative selection method. *IEEE Trans. System, Man and Cybernetics*, 3(8):630–632.

- [Robert-Granié et al., 2002] C. Robert-Granié, E. Maza, R. Rupp, J. L. Foulley, Utilisation des polynômes fractionnaires pour la modélisation de la courbe moyenne des scores de cellules somatiques dans le lait chez les bovins laitiers. JSBL2002, Louvain-la-Neuve.
- [Romaniuk et al., 2003] B. Romaniuk , M. Desvignes , M. Revenu, M.-J. Deshayes, "Modélisation statistique de lignes et de points par courbes de Bézier composites" , GRETSI'2003,
- [Rosenberger, 1999] C. Rosenberger. Mise en Oeuvre d'un Système Adaptatif de Segmentation d'Images. Thèse de Doctorat, Université de Rennes 1, decembre 1999.
- [Royston et Altman, 1994] Royston P. et Altman D. G., Regression using fractional polynomials of continuous covariates: parsimonious parametric modelling, Appl. Stat., 43, 429-467, 1994.
- [Sahoo et al., 1988] P. K. Sahoo, S. Soltani, A. K. C.Wong, et Y. C. Chen. A survey of thresholding techniques. CVGIP, 41 : 233–260, 1988.
- [Sakas et Walter, 1995] G. Sakas, S. Walter, "Extracting Surfaces from Fuzzy 3D-ultrasound Data", 1995. In International Conference on Computer Graphics and Interactive Techniques, 8, 465-474.
- [Sankur et Sezgin, 2004] Sankur, B. et Sezgin, M. (2004). Survey over image thresholding techniques and quantitative performance evaluation. Journal of Electronic Imaging, 13(1):146–165.
- [Sarkar et al., 2003] B. Sarkar, L.K. Singh, D. Sarkar, "Approximation of digital curves with line segments and circular arcs using genetic algorithms", Pattern Recognition Lett. 24:2585-2595, 2003.
- [Schroeter et al., 1998] P. Schroeter, J.-M. Vesin, T. Langenberger, and R. Meuli. Robust parameter estimation of intensity distributions for brain magnetic resonance images. IEEE Trans. Medical Imaging, 17(2):172-186, 1998.
- [Shaffrey et al., 2002] C. W. Shaffrey, Ian H. Jermyn, et N. G. Kingsbury, editors. Psychovisual Evaluation of Image Segmentation Algorithms. ACIVS (Advanced Concepts for Intelligent Vision Systems), september 2002.
- [Shannon, 1948] C.E. Shannon. A mathematical theory of communication. Bell Sys. Tech. Journal, 27 : 379–423, 623–656, juillet et octobre 1948.
- [Shufelt, 1999] J. A. Shufelt. Performance Evaluation and Analysis of monocular building extraction from aerial imagery. Transaction on Pattern Analysis and Machine Intelligence, 21(4) : 311–326, 1999.
- [Sonka et al., 1998] M. Sonka, V. Hlavac, and R. Boyle, Image Processing, Analysis and Machine Vision. Chapman and Hall Computing, 1998.
- [Sweldens, 1997] Sweldens, W., 1997. The lifting scheme: a construction of second generation wavelets. SIAM J. Math. Anal. 29 (2), 511–546.
- [Tan et al., 1992] H. L. Tan, S. B. Gelfand, et Delp. A cost minimization approach to edge detection using simulated annealing. IEEE Transactions on Pattern Analysis and Machine Intelligence, 14 : 3–18, 1992.
- [Teh et Chin, 1989] Teh, C.H., and Chin, R.T., On the Detection of Dominant Points on Digital Curve, PAMI(11), No. 8, August 1989, pp. 859-872.
- [Terzopolous et al., 1998] D. Terzopolous, M. Kaas, and A. Witkin, "Constraints on Deformable Models: Recovering 3-D Shape and Non-rigid Motion," Artificial Intelligence Journal, vol. 36, pp. 91-123, 1998.
- [Trémeau et al., 2004] A. Trémeau, C. Fernandez-Maloigne, and P. Bonton. Image numérique couleur. Dunod, Paris, 2004

- [Truong et al., 2000] T.-K. Truong, J.-H. Jeng, I.S. Reed, P.C. Lee, et A.Q. Li. A fast encoding algorithm for fractal image compression using the dct inner product. *IEEE Transactions on Image Processing*, 9(4) :529\_535, Avril 2000.
- [Tuceryan et Jain, 1993] Tuceryan, M., and Jain, A.K., *Texture Analysis*, HPRCV92(II-1), 1993, pp. 235-276. Texture review.
- [Van Rijsbergen, 1979] van Rijsbergen, C. J. (1979). *Information Retrieval* (second ed.). London : Butterworths.
- [Vinet, 1991] L. Vinet. *Segmentation et mise en correspondance de régions de paires d'images stéréoscopiques* Thèse de Doctorat de l'université de Paris IX Dauphine, 1991.
- [Wall et Danielsson, 1984] K. Wall, P.E. Danielsson "A fast sequential method for polygonal approximation of digitized curves", *Computer Vision Graphics and Image Processing* 28:220-227, 1984.
- [Wang et Lee, 1999] S. L. Yu-Ping Wang and K. T. Lee, "Multiscale curvature based shape representation using b-spline wavelets," *IEEE Trans. Image Processing*, vol. 8, no. 11, pp. 1586–1592, 1999.
- [Wei, 2001] Li-Yi Wei, « Texture synthesis by fixed neighborhood searching », Dissertation for the degree of doctor of philosophy, department of electrical engineering and the committee on graduate studies of Stanford University, November 2001
- [Weszka et Rosenfeld, 1978] J. S. Weszka et A. Rosenfeld. Threshold evaluation techniques. *IEEE Trans., SMC-8* : 622–629, 1978.
- [Wilson et al., 1997] D. L. Wilson, A. J. Baddeley, et R. A. Owens. A new metric for grey-scale image comparison. *International Journal of Computer Vision*, 24(1) : 5–17, 1997.
- [Yang, 1988] H.S.Yang, *Range Image Segmentation and Classification Via Split and Merge Based on Surface Curvature*, *Proceedings of 4th International Conference on Pattern Recognition*, pp. 58-67, 1988
- [Zahid et al., 1999] A. N. Zahid. O. Abouelala, M. Limouri, "Unsupervised fuzzy clustering", *Pattern Recognition Letters*, 20 (1999), pp. 123-129.
- [Zair, 1998] Zair (Chems Eddine). – *Formes fractales à pôles basées sur une généralisation des IFS*. – Thèse de doctorat, Université Claude Bernard Lyon 1, Juin 1998.
- [Zamperoni et Starovoitov, 1996] P. Zamperoni et V. Starovoitov. On measures of dissimilarity between arbitrary gray-scale images. *International Journal of Shape Modeling*, 2 : 189–213, 1996.
- [Zhang, 1996] Y. J. Zhang. A survey on evaluation methods for image segmentation. *Pattern Recognition*, 29(8) : 1335–1346, 1996.
- [Zhang et al., 2004] Zhang, X.-W., Song, J., Lyu, M. R. et Cai, S. (2004). Extraction of karyocytes and their components from microscopic bone marrow images based on regional color features. *Pattern Recognition*, 37:351–361.
- [Zhu et Yuille, 1996] Zhu, S. et Yuille, A. (1996). Region competition : Unifying snakes, region growing, and bayes/mdl for multiband image segmentation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 18(9):884–900.

