

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOULOU MAMMERI, TIZI-OUZOU



FACULTE DE GENIE ELECTRIQUE ET DE L'INFORMATIQUE
DEPARTEMENT D'ELECTRONIQUE

Mémoire de fin d'études

En vue de l'obtention

Du Diplôme de Master en Electronique

Option : Réseaux et télécommunication

Thème :

***Segmentation multi-résolution d'images texturées par
approche markovienne***

Proposé et dirigé par :

Mme AMEUR Zohra

Présenté par :

Mr MAAMERI Karim

Mr MAZOUNI Amirouche

Année universitaire 2010/2011

Dédicaces

Je dédie notre modeste travail à :

- ✚ Mes très chers parents pour leur aide et leur soutien tout au long de mes études et dans les moments difficiles.*
- ✚ Ma très chère famille, mon frère Samir, mes sœurs Lila, Kahina et son mari Faredj et la petite Sarah.*
- ✚ Mes très chers amis, Rabah et Dalila.*
- ✚ Toute la promotion 2011.*

Karim

Dédicaces

Je dédie ce modeste travail à :

- ✚ Mes parents, pour leurs conseils précieux et leurs encouragements ;*
- ✚ Mon frère Massinissa, et mes sœurs ;*
- ✚ Mes chers amis et tous ceux qui me sont chers ;*
- ✚ Toute la promo de Master 2 d'électronique, 2010-2011,*

Amirouche

Remerciements

Ce travail a été réalisé à l'université Mouloud Mammeri de Tizi Ouzou (UMMTO) sous la direction de madame AMEUR Zohra.

Nous remercions particulièrement notre promotrice Madame AMEUR pour son soutien, sa disponibilité, son enthousiasme et sa gentillesse. Nous la remercions aussi pour ses précieux conseils et ses orientations qui nous ont permis de mener à bien ce projet.

Nous remercions également, Monsieur ALOUACHE Djamel pour sa disponibilité, ses conseils et sa gentillesse tout au long de notre travail.

Résumé

La segmentation d'images texturées reste une tâche essentielle pour des traitements et analyses ultérieurs.

La modélisation par champs de Markov est un outil puissant permettant d'aboutir à un bon résultat dans de nombreux domaines.

Dans ce mémoire, nous proposons d'effectuer une segmentation d'images texturées en utilisant les champs de Markov.

Dans un premier temps, nous effectuerons la transformée en ondelettes à l'image initiale et ensuite, estimerons localement sur les sous images (coefficients) les paramètres de la texture.

Les paramètres calculés permettront alors de décrire, de caractériser, d'analyser et de segmenter les images en question.

Mots clés : segmentation d'images, champs de Markov, champs de Gibbs, ondelettes, images texturées, multi-résolution.

Table des matières

| | |
|----------------------------|-----|
| Dédicaces | i |
| Remerciements | iii |
| Résumé | iv |
| Table des matières | v |
| Liste des figures..... | x |
| Liste des tableaux | xi |
| Introduction générale..... | xii |

Chapitre I : Introduction au traitement d'image

| | |
|--|---|
| Préambule | 1 |
| I.1 Définition de l'image | 2 |
| I.2 Image numérique..... | 2 |
| I.2.1 Qualité d'une image numérique | 3 |
| I.2.2 Caractéristiques d'une image numérique | 3 |
| I.2.2.1 Pixel..... | 3 |
| I.2.2.2 Dimension | 4 |
| I.2.2.3 Résolution..... | 4 |
| I.2.2.4 Contraste..... | 4 |
| I.2.2.5 bruit | 4 |
| I.2.2.6 contour..... | 4 |
| I.2.2.7 luminance | 5 |
| I.3 Image bitmap et image vectoriel | 5 |
| • les images bitmap | 5 |
| • Les images vectorielles..... | 5 |
| I.4 Types d'images | 6 |
| I.4.1 image binaire | 6 |
| I.4.2 image couleur | 6 |
| I.4.3 image en niveau de gris | 7 |
| I.5 Système de traitement d'image | 7 |
| I.5.1 Acquisition des données image | 7 |

| | |
|---|----|
| I.5.2 Prétraitement et post traitement..... | 8 |
| I.5.3 Le traitement numérique des images..... | 8 |
| I.5.4 La visualisation | 8 |
| I.6 Notion d’histogramme..... | 8 |
| I.6.1 Histogramme uni modal | 9 |
| I.6.2 Histogramme bimodal | 9 |
| I.6.3 Histogramme multimodal..... | 9 |
| I-7-Prétraitement des images | 9 |
| I.7.1 Modification d’histogramme..... | 10 |
| I.7.1.1 Egalisation d’histogramme..... | 11 |
| I.7.1.2 Etirement d’histogramme..... | 11 |
| I.7.1.3 le seuillage..... | 12 |
| I.7.2 Expansion dynamique | 12 |
| I.7.4 Réduction de bruit | 12 |
| I.8 Les filtres..... | 13 |
| I.8.1 Les filtres linéaires | 13 |
| I.8.1.1 Filtre passe bas | 13 |
| I.8.1.2 Filtre passe haut..... | 13 |
| I.8.1.3 Filtre passe-bande | 14 |
| I.8.2 Les filtres non linéaires | 14 |
| I.8.2.1 Filtre d’ordre | 14 |
| I.8.2.2 Filtre position | 15 |
| I.8.2.3 Filtre médian | 15 |
| I.9 Rehaussement de contraste..... | 15 |
| Discussion..... | 15 |

Chapitre II : Segmentation d’images texturées

| | |
|-------------------------------------|----|
| Préambule | 16 |
| II .1Définition de la texture | 17 |
| II.1.1Texture périodique | 17 |
| II.1.2 Texture stochastique | 18 |

| | |
|--|----|
| II.1.3 Texture hybride | 18 |
| II .2 Méthodes d'analyse de textures | 19 |
| II.2.1 Extraction des données structurelles | 20 |
| II.2.2 Extraction de données spatio-fréquentielles | 20 |
| II.2.2.1 Méthode basée sur le spectre de puissance | 20 |
| II.2.2.2 Masques de Laws | 21 |
| II.2.3 Extraction de données statistiques | 22 |
| II.2.3.1 Analyse texturale par cooccurrence | 22 |
| II.2.3.2 Méthode de la décomposition morphologique..... | 22 |
| II.2.3.3Matrices de longueurs de plages | 22 |
| II.3Segmentation d'images | 23 |
| ➤ Segmentation d'images texturées | 23 |
| II.4Les méthodes de segmentation de textures | 23 |
| II.4.1Segmentation par région | 23 |
| ➤ Méthode par séparation (Quad-Tree) | 24 |
| ➤ Méthode par fusion | 24 |
| ➤ Méthode par séparation/fusion | 24 |
| II.4.2Méthodes de détection de contours | 24 |
| II .4.3Les méthodes markoviennes pour la segmentation | 25 |
| II.4.4 Segmentation basée sur les pixels (approche classification) | 25 |
| ➤ Méthode de K-means | 26 |
| II .4.5La segmentation coopérative | 26 |
| Discussion..... | 28 |

Chapitre III : Ondelettes et multi-résolution

| | |
|---|----|
| Préambule | 29 |
| III.1 La transformée de Fourier | 29 |
| III.2 La transformée de Fourier à fenêtre glissante | 30 |
| III.3 La transformée en ondelettes | 31 |
| III.3.1 Définition et propriétés | 31 |
| III.3.2 La transformation en ondelettes continues | 33 |
| III.3.3 La transformée en Ondelettes Discrète..... | 33 |

| | |
|--|----|
| III.3.4 Bases orthonormées d'ondelettes | 34 |
| III.4 Analyse multi-résolution | 34 |
| III.4.1 Définition de L'analyse en Multi-résolution | 35 |
| III.5 Algorithme de S.MALLAT par l'approche de convolution | 37 |
| III.5.1 Algorithme unidimensionnel | 37 |
| III.5.1.1 Décomposition..... | 37 |
| III.5.1.2 Reconstruction | 39 |
| III.5.2 Algorithme bidimensionnel | 39 |
| III.5.2.1 Décomposition..... | 40 |
| III.5.2.2 Reconstruction | 41 |
| Discussion..... | 42 |

Chapitre IV : segmentation par approche markovienne multi-résolution

| | |
|--|----|
| Préambule | 43 |
| IV.1 Modélisation d'une image | 44 |
| IV.2 Notion de la théorie des graphes | 44 |
| IV.2.1 Système de voisinage | 44 |
| IV.2.2 Notion de clique | 45 |
| IV.3 Champs de Markov et distributions de Gibbs | 46 |
| IV.3.1 Champs de Markov | 46 |
| IV.3.2 Champs de Gibbs..... | 46 |
| IV.3.3 Théorème de Hammersley_Clifford..... | 47 |
| IV.4 Modélisation markovienne | 47 |
| IV.4.1 Position du problème de la segmentation d'image..... | 47 |
| IV.4.2 Estimation bayésienne | 48 |
| IV.4.2.1 Estimateur au sens du maximum a posteriori(MAP) | 49 |
| IV.4.3 Modélisation du champ des observations..... | 50 |
| IV.4.4 Modélisation markovienne du champ des classes..... | 50 |
| IV.5 Hypothèses markoviennes | 50 |
| IV.5.1 Fonction d'énergie globale..... | 51 |
| IV.6 Algorithme de minimisation..... | 51 |

| | |
|---|----|
| IV.7 Model markovien multi résolution | 53 |
| IV.8 Méthode adoptée | 55 |
| IV.8.1 Présentation de la méthode de segmentation adoptée | 55 |
| IV.8.2 Décomposition en ondelette | 55 |
| IV.8.3 Classification par la méthode des K-means | 55 |
| IV.8.4 Phase de segmentation..... | 57 |
| Discussion..... | 59 |

Chapitre V : tests et résultats

| | |
|---|----|
| Préambule | 60 |
| V. Présentation des données | 61 |
| V.1 Images de Brodatz | 61 |
| V.1.2 Images Météosat | 62 |
| V.2 Présentation du logiciel utilisé..... | 62 |
| V.3 Application de la méthode | 63 |
| V.3.1 Cas des images tests de Brodatz | 63 |
| A) Le premier niveau de décomposition | 63 |
| B)Deuxième niveau de décomposition..... | 65 |
| C)Troisième niveau de décomposition | 66 |
| V.3.2 Cas des images Météosat | 68 |
| A) Le premier niveau de décomposition | 68 |
| B)Deuxième niveau de décomposition..... | 70 |
| C)Troisième niveau de décomposition | 71 |
| V.4 Interprétation des résultats | 73 |
| V.5 Discussion..... | 74 |
| Conclusion | 75 |
| Annexe..... | 76 |
| Bibliographies..... | 80 |

Liste des figures

| | |
|---|----|
| Figure 1 : pixels et niveaux de gris..... | 2 |
| Figure2 : Image présentant l’affichage des pixels..... | 3 |
| Figure 3 : image vectorielle et bitmap..... | 5 |
| Figure 4 : Image Léna en noir et blanc..... | 6 |
| Figure 5 : Image Léna en couleurs..... | 6 |
| Figure 6 : Image Léna en niveau de gris..... | 7 |
| Figure 7 : Image Léna et son histogramme..... | 8 |
| Figure8 : histogrammes..... | 9 |
| Figure9 : modification d’hisogramme..... | 10 |
| Figure 10 : Effet de l’égalisation d’histogramme..... | 11 |
| Figure11 : filtrage passe-bas..... | 13 |
| Figure12 : filtrage passe-haut..... | 14 |
| Figure 13 : exemple de texture périodique..... | 18 |
| Figure 14 : exemple de texture stochastique..... | 18 |
| Figure 15 : exemple de texture hybride..... | 19 |
| Figure 16 : Etapes de segmentation D’images..... | 27 |
| Figure 17 : Fenêtre de Gabor décalée d’un temps τ | 31 |
| Figure 18 : exemples d’ondelettes..... | 32 |
| Figure 19 : le schéma illustre le principe de multi-résolution..... | 35 |
| Figure 20 : Schéma de Décomposition unidimensionnelle de l’algorithme de S.Mallat..... | 38 |
| Figure 21 : Schéma de la reconstruction unidimensionnelle de l’algorithme de S.Mallat..... | 39 |
| Figure 22 : Analyse d’un signal bidimensionnel par l’algorithme de S. Mallat..... | 40 |
| Figure 23: Schéma de reconstruction de Mallat..... | 41 |
| Figure 24 : schéma de décomposition d’une image à 2D..... | 42 |
| Figure 25 : Systèmes de voisinage 2D..... | 45 |
| Figure 26 : Les cliques associées aux systèmes de voisinage 2D..... | 45 |
| Figure 27 : structuration pyramidale des étiquettes et des observations en vue de l’utilisation d’un modèle markovien multi-résolution..... | 54 |
| Figure 28 : L’organigramme représentant les différentes étapes de la méthode élaborée..... | 58 |
| Figure 29.a : Text1..... | 61 |

| | |
|--|----|
| Figure 29.b : Text2 | 61 |
| Figure 29.c : Text3..... | 61 |
| Figure 30.a : Image 1 (visible)..... | 62 |
| Figure 30.b : Image2 (infra-R) | 62 |
| Figure 31: Résultat de la segmentation de l'image test1 | 63 |
| Figure 32: Résultat de la segmentation de l'image test2..... | 64 |
| Figure 33: Résultat de la segmentation de l'image test3 | 64 |
| Figure 34: Résultat de la segmentation de l'image test1 | 65 |
| Figure 35: Résultat de la segmentation de l'image test2..... | 65 |
| Figure 36: Résultat de la segmentation de l'image test3 | 65 |
| Figure 37: Résultat de la segmentation de l'image test1 | 66 |
| Figure 38: Résultat de la segmentation de l'image test2..... | 66 |
| Figure 39 : Résultat de la segmentation de l'image test3 | 67 |
| Figure 40 : Résultat de la segmentation de l'image1 avec différentes classes | 68 |
| Figure 41 : Résultat de la segmentation de l'image2 avec différentes classes | 69 |
| Figure 42 : Résultat de la segmentation de l'image1 avec différentes classes | 70 |
| Figure 43 : Résultat de la segmentation de l'image2 avec différentes classes | 71 |
| Figure 44 : Résultat de la segmentation de l'image1 avec différentes classes | 72 |
| Figure 45 : Résultat de la segmentation de l'image2 avec différentes classes | 72 |

Liste des tableaux

| | |
|---|----|
| Table1 : Différent masque de Laws 3x3..... | 21 |
| Table2 : Les masques de Laws 5x5 | 21 |
| Table3 : Données de la segmentation des images test..... | 64 |
| Table4 : Données de la segmentation des images test..... | 66 |
| Table5 : Données de la segmentation des images test..... | 67 |
| Table6 : Données de la segmentation des images 1 et 2 | 69 |
| Table7 : Données de la segmentation des images 1 et 2 | 71 |
| Table8 : Données de la segmentation des images 1 et 2 | 73 |

Introduction générale

Chacun peut analyser l'image à sa manière, pour en dégager une impression et d'en extraire des informations précises. Dans le but de rendre cette opération possible, plus simple, plus efficace, plus agréable et d'améliorer l'aspect visuel, le traitement d'images existe à cet effet.

Dans le traitement d'images, la segmentation est une étape fondamentale dans la mesure où elle conditionne l'interprétation de l'image. En effet, elle a pour objectif l'extraction des éléments pertinents de l'image, et permet également la description de l'information contenue dans l'image en donnant une représentation plus condensée et facilement exploitable. C'est pour cela que de nombreux algorithmes de segmentation d'images ont été proposés durant ces dernières décennies, reposant sur les différentes approches : contour, région et texture.

Contrairement aux méthodes de segmentation d'images qui utilisent le seul paramètre qui est le niveau de gris, beaucoup d'images, et plus particulièrement les images texturées qui nécessitent l'introduction des autres paramètres de texture dans les algorithmes de segmentation.

Dans ce mémoire, nous présentons une technique basée sur une méthode « markovienne multi-résolution ». Notons que diverses études ont mis en évidence la puissance de cette méthode dans la caractérisation de texture.

Dans un premier temps, nous effectuerons la transformée en ondelettes à l'image initiale et ensuite, estimerons localement sur les sous images les paramètres de la texture. Les paramètres calculés permettront alors de décrire, de caractériser, d'analyser et de segmenter les images en question.

Compte tenu de cet objectif, nous avons opté pour le plan de travail suivant :

- Le premier chapitre abordera les définitions et les notions de base utilisées en traitement d'images.
- Le deuxième chapitre sera consacré à l'étude des principales méthodes d'analyse et de segmentation d'images texturées.
- Le troisième chapitre décrira la théorie des ondelettes et multi-résolution.
- Le quatrième chapitre détaillera la théorie des champs de Markov et la méthode adoptée.
- Le dernier chapitre sera consacré à la présentation des résultats et leurs interprétations.

Enfin, nous terminerons notre travail par une conclusion.

Chapitre I

Introduction au traitement d'image

Préambule

Le traitement d'image est né de l'idée et de la nécessité de remplacer l'observateur humain par la machine. L'image ou les signaux provenant des capteurs ont alors été numérisés pour pouvoir être traités par ordinateur.

Avec la parole, l'image constitue l'un des moyens les plus importants qu'utilise l'être humain pour communiquer avec autrui. C'est un moyen de communication universel dont la richesse du contenu permet aux individus de tout âge et de toute culture de se comprendre.

C'est aussi le moyen le plus efficace pour communiquer, chacun peut alors analyser l'image à sa manière, pour en dégager une impression et en extraire des informations précises.

De ce fait, le traitement d'image est l'ensemble des méthodes et techniques permettant d'améliorer facilement et efficacement l'aspect visuel d'une image, puis d'en extraire les informations jugées pertinentes.

On distingue quatre types de traitement formant ainsi quatre disciplines:

- Rehaussement et restauration d'image.
- Codage et compression d'image.
- Synthèse d'image.
- Analyse d'image.

Dans ce chapitre nous donnerons une brève explication sur les notions fondamentales indispensable à connaître pour toute étude dans ce domaine.

I.1 Définition de l'image

L'image n'est qu'une représentation planaire d'un objet, d'une scène située en général dans un espace tridimensionnel.

L'image peut être représentée sous forme d'un ensemble de points repartis dans une surface donnée. La valeur de chaque point est la réalisation d'une variable aléatoire liée à l'apparition de la luminance dans un site donné de l'image. Sur l'écran de visualisation, une image numérique se présente comme ensemble de points appelés pixels ayant L lignes et K colonnes. On dit alors que l'image possède une dimension de K*L pixels. Le mot « pixel » vient de l'expression anglaise « Picture Element » qui veut dire élément d'image.

Une image peut être considérée comme un signal bidimensionnel variant dans l'espace suivant les directions horizontales X et verticales Y.

I.2 Image numérique

Contrairement aux images obtenues à l'aide d'un appareil à photo ou dessinées sur du papier, les images manipulées par un ordinateur sont numériques (représentées par une série de bits).

L'image numérique est l'image dont la surface est divisée en éléments de tailles fixes appelés cellules ou pixels, ayant chacune comme caractéristique un niveau de gris ou de couleurs prélevé à l'emplacement correspondant dans l'image réelle, ou calculé à partir d'une description interne de la scène à représenter.




Figure 1 : pixels et niveaux de gris

I.2.1 Qualité d'une image numérique

Elle dépend, d'une part, de la qualité des images d'origine et, d'autre part, des moyens mis en œuvre pour convertir un signal analogique en un signal numérique. Elle dépend aussi de :

- La qualité des périphériques de numérisation de l'image, du nombre de niveau de gris ou couleurs enregistrées.
- La qualité de l'affichage à l'écran : définition de l'écran, nombre de teintes disponibles simultanément, calibrage de l'écran,....

Les critères d'appréciation de la qualité d'une image, tels que cités succinctement ci-dessus, dépendent largement de la structure même de l'image réaliste ou conceptuelle et de son mode de représentation (bitmap ou vectorielle).

I.2.2 Caractéristiques d'une image numérique

L'image est un ensemble structuré d'informations caractérisées par plusieurs paramètres que nous décrivons ci-après.

I.2.2.1 Pixel

Pour un ordinateur, une image est un ensemble de pixels. Un pixel est un élément d'image (picture element). C'est le plus petit élément qui constitue l'image.




Figure2 : Image présentant l'affichage des pixels

Un pixel possède une valeur qui peut être un scalaire et représente un niveau de gris, ou un vecteur représentant une couleur.

La quantité d'information que véhicule chaque pixel donne des nuances entre images monochromes et images couleurs. Dans le cas d'une image monochrome, chaque pixel est codé sur un octet, et la taille mémoire nécessaire pour afficher une telle image est directement liée à la taille de l'image. Dans une image couleur(R.V.B), un pixel est codé sur trois octets : un octet pour chacune des couleurs : Rouge(R), Vert(V), Bleu(B).

I.2.2.2 Dimension

Comme la représentation de l'image est une matrice dont les éléments sont des valeurs numériques, donc la multiplication du nombre de lignes par le nombre de colonnes nous donnera la taille de l'image.

I.2.2.3 Résolution

C'est la finesse de détails atteinte par un moniteur dans la production d'image sur l'écran d'ordinateur.

La résolution est exprimée en nombre de pixels par unité de mesure (pouce ou centimètre). On utilise aussi le mot résolution pour désigner le nombre total de pixels affichables horizontalement ou verticalement sur un moniteur. Plus le nombre de pixels est grand plus la résolution est meilleure.

I.2.2.4 Contraste

Le contraste est défini en fonction des luminances entre deux zones d'image, plus précisément entre les régions sombres et les régions claires de cette image. Si L_1 et L_2 sont les degrés de luminosité respectivement de deux zones voisines A_1 et A_2 d'une image, le contraste C est défini par le rapport :

$$C = \frac{L_1 - L_2}{L_1 + L_2}$$

(I.1)

I.2.2.5 bruit

Le bruit est un phénomène de brusque variation de niveau d'un pixel par rapport à ces voisins. Il peut provenir de l'éclairage, des dispositifs optiques et électroniques du capteur.

I.2.2.6 contour

Les contours représentent les frontières entre les objets de l'image ou la limite entre deux pixels dont le niveau de gris représente une différence significative.

I.2.2.7 Luminance

C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface, pour un observateur lointain, le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet.

La moyenne ou luminance (brillance) d'une image numérique en niveau de gris est définie comme la moyenne des pixels de l'image :

$$(I.2) \quad \text{LUM} \quad (I) \quad = \quad \frac{1}{M \times N} \quad \sum_{x=0}^{M-1} \cdot \sum_{y=0}^{N-1} f(x, y)$$

Avec :

M : Nombre de colonnes,

N: Nombre de lignes,

F(x, y) : La valeur de niveau de gris dans le point (x, y).

I.3 Image bitmap et image vectoriel

On distingue généralement deux grandes catégories d'images :

- **les images bitmap** : il s'agit d'images pixellisées, c'est-à-dire un ensemble de points (pixels) contenus dans un tableau, chacun de ces points possédant une ou plusieurs valeurs décrivant sa couleur.
- **les images vectorielles**: les images vectorielles sont des représentations d'entités géométriques telles qu'un cercle, un rectangle ou un segment. Ceux-ci sont représentés par des formules mathématiques (un rectangle est défini par deux points, un cercle par un centre et un rayon, une courbe par plusieurs points et une équation). C'est le processeur qui sera chargé de "traduire" ces formes en informations interprétables par la carte graphique.

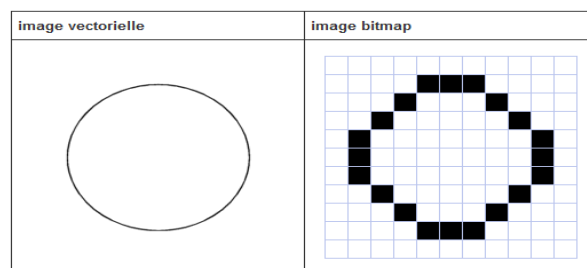


Figure 3 : image vectorielle et bitmap

I.4 Types d'images

I.4.1 Image binaire

Une image binaire est une matrice rectangulaire dont le nombre de niveaux de gris est déduit aux deux éléments 0 et 1, où le niveau 0 représente le noir absolu et le niveau 1 représente le blanc. On n'utilise dans ce cas qu'un seul bit pour coder le niveau de gris.



Figure 4 : Image Léna en noir et blanc.

I.4.2 Image couleur

Même s'il est parfois utile de pouvoir représenter des images en noir et blanc, les applications multimédia utilisent souvent des images en couleur. La représentation des couleurs s'effectue de la même manière que les images monochromes avec cependant quelques particularités. En effet, il faut tout d'abord choisir un modèle de représentation. On peut représenter les couleurs à l'aide de leurs composantes primaires. Les systèmes émettant de la lumière (écran d'ordinateur,...) sont basés sur le principe de la synthèse additive. Les couleurs sont alors composées d'un mélange de rouge, vert et bleu (modèle R.V.B).



Figure 5 : Image Léna en couleurs

I.4.3 image en niveau de gris

Le niveau de gris est la valeur de l'intensité lumineuse en un point. Le pixel peut prendre des valeurs allant du noir au blanc en passant par un nombre fini de niveaux intermédiaire. Donc pour représenter les images en niveaux de gris, on peut attribuer à chaque pixel de l'image une valeur correspondant à la quantité de lumière renvoyée. Cette valeur peut être comprise par exemple entre 0 et 255. La valeur zéro représente le noir (intensité lumineuse nulle) et la valeur 255 le blanc (intensité lumineuse maximale). En effet chaque entier représentant un niveau de gris est codé sur 8 bits. Pour cela, il faut que le matériel utilisé pour afficher l'image soit capable de produire les différents niveaux de gris correspondant.



Figure 6 : Image Léna en niveau de gris.

I.5 Système de traitement d'image :

Un système de traitement d'image regroupe les fonctions suivantes :

I.5.1 Acquisition des données image :

Le passage de l'image originale à sa représentation dans l'unité de traitement se fait grâce à une procédure de numérisation et ce, en utilisant des périphériques d'acquisition tels que les caméras numériques et les scanners. On trouve aussi des cartes d'acquisition qui fonctionnent grâce à un capteur CCD (Charged Coules Device).

I.5.2 Prétraitement et post traitement :

Le prétraitement concerne les images acquises tandis que le post traitement concerne les images traitées. Pour pallier aux dégradations de l'image, on utilise en générale le filtrage. Parmi ces filtrages nous distinguons :

- Filtre médian.
- L'érosion
- La dilatation.

Ces différents filtres seront détaillés dans ci-dessous (voir section I.8)

I.5.3 Le traitement numérique des images :

Le traitement d'image est l'ensemble des méthodes qui permettent de décrire quantitativement le contenu d'une image. On distingue plusieurs étapes qui sont : l'acquisition, la numérisation, le prétraitement, la segmentation et l'interprétation.

I.5.4 La visualisation

Tout système de traitement d'image est doté d'un dispositif de visualisation qui permet l'affichage des images. La transformation du signal numérique qui est la matrice image en un signal analogique visible par l'œil se fait grâce aux différents types de supports tels que le moniteur, les clichés photographiques et l'impression sur papier.

I.6 Notion d'histogramme

L'histogramme des niveaux de gris de l'image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris. L'histogramme permet alors de donner la distribution des niveaux de gris de l'image appelée « dynamique de l'image ».

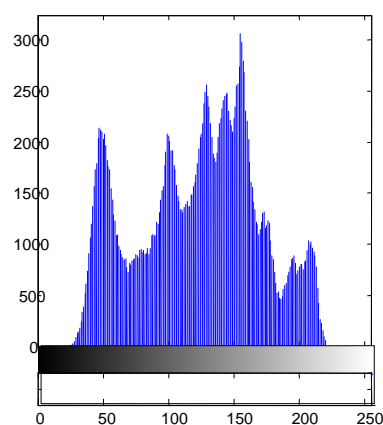


Figure 7 : Image Léna et son histogramme.

L'histogramme est un outil privilégié en analyse d'image car il donne un résumé simple, mais souvent suffisant du contenu de l'image. On peut distinguer trois types d'histogramme d'image :

I.6.1 Histogramme uni modal

Ce type d'histogramme n'a qu'un seul pic, il présente soit un objet soit un fond.


I.6.2 Histogramme bimodal

Il est formé de deux modes bien séparés (deux pics séparés par une vallée) et l'on déduit ainsi qu'il existe un objet sur un fond.


I.6.3 Histogramme multimodal

Il est formé de plusieurs modes séparés (plusieurs pics séparés par plusieurs vallées) qui nous renseigne sur la présence de plusieurs objets.


Les schémas



Histogramme uni modal



Histogramme bi modal



Histogramme multimodal

Figure8 : histogrammes

I.7 Prétraitement des images :

Le prétraitement est une opération fondamentale en traitement d'image. Il permet d'améliorer la perception de certains détails, de réduire le bruit, de compenser certains défauts du capteur, et aussi pour faciliter l'analyse d'une image en forçant la ressemblance entre pixels appartenant à une même région, ou en accentuant la dissemblance entre pixels, situé dans un proche voisinage du pixel courant.

Le prétraitement est nécessaire notamment dans les cas suivants :

- ✓ L'image est bruitée.
- ✓ Le contraste n'est pas suffisant.
- ✓ L'éclairage de l'image n'est pas uniforme

Dans le paragraphe suivant nous présenterons quelques méthodes de prétraitement les plus utilisées et qui sont :

I.7.1 Modification d'histogramme

L'histogramme est un outil très utile pour étudier la répartition des composantes d'une image. Sa modification est généralement représentée sur une courbe (appelée courbe tonale) indiquant la modification globale des composantes de l'image avec en abscisse les valeurs initiales et en ordonnées les valeurs après modification. La courbe tonale correspond à une fonction de transfert définie par une table de transcodage appelé look up, notée LUT. Ainsi la diagonale indique la courbe telle que les valeurs initiales sont égales aux valeurs finales, c'est-à-dire lorsqu'aucune modification n'a eu lieu (voir la figure9) les valeurs à gauche de la valeur moyenne sur l'axe des abscisses représente les pixels foncés tandis que ceux à droite représente les pixels claires.




Figure9 : modification d'histogramme

I.7.1.1 Egalisation d'histogramme

L'Egalisation d'histogramme est un outil qui est parfois utile pour améliorer certaines images de mauvaise qualité (mouvais contraste, image trop sombres ou trop claires, ..).

Il s'agit de déterminer une transformation f des niveaux d'intensité qui rend l'histogramme aussi plat que possible. Si un pixel a une intensité i dans l'image originale, son intensité dans l'image égalisée est $f(i)$. En général, on choisit pour f une fonction en escalier, et on détermine la largeur et la hauteur des différentes marches de manière à aplatir l'histogramme de l'image égalisée.

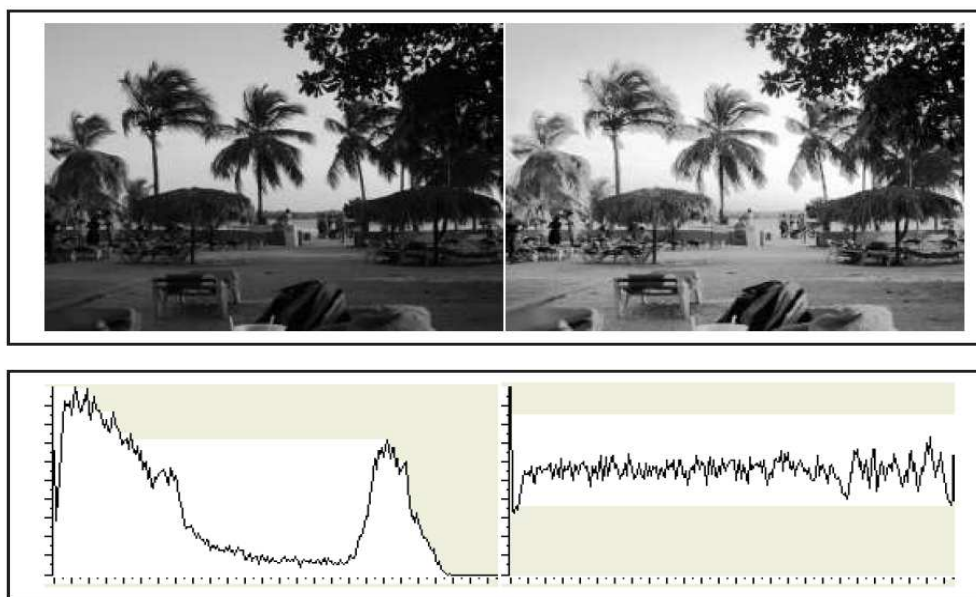


Figure 10: Effet de l'égalisation d'histogramme.

I.7.1.2 Etirement d'histogramme

L'étirement d'histogramme (aussi appelé *linéarisation d'histogramme*) consiste à répartir des fréquences d'apparition des pixels sur la largeur de l'histogramme. Ainsi, il s'agit d'une opération consistant à modifier l'histogramme de telle manière à répartir aux mieux les intensités sur l'échelle des valeurs disponibles. Ceci revient à étendre l'histogramme afin que la valeur d'intensité la plus faible soit à zéro et que la plus haute soit à la valeur maximale.

De cette façon, si les valeurs de l'histogramme sont très proches les une des autres, l'étirement va permettre de fournir une meilleure répartition afin de rendre les pixels clairs encore plus clair et les pixels foncés proches du noir.

I.7.1.3 le seuillage

L'opération dite de « seuillage simple » consiste à mettre à zéro tous les pixels ayant un niveau de gris inférieur à une certaine valeur (appelé seuil, en anglais *threshold*) et à la valeur maximale les pixels ayant une valeur supérieure. Ainsi le résultat du seuillage est une image binaire contenant les pixels noirs et blanc. C'est la raison pour laquelle le terme de binarisation est parfois employé. Le seuillage permet de mettre en évidence des formes ou des objets dans une image. Toutefois, la difficulté réside dans le choix du seuil à adopter.

I.7.2 Expansion dynamique

Cette méthode consiste à utiliser au mieux la dynamique des niveaux de gris. Ainsi, si une image possède des niveaux de gris entre a_0 et a_1 , on va étendre la plage des niveaux de gris pour la ramener à une dynamique comprise entre 0 et 255. Cette étendue réduite de niveaux de gris peut survenir suite à un éclairage de scène trop faible. Cette méthode ne fait qu'améliorer l'aspect visuel de l'image, elle ne change pas l'information présente dans le signal.

I.7.3 Réduction de bruit

Les régions formant l'image sont caractérisées par leur intensité moyenne. Les fluctuations autour de cette intensité moyenne peuvent provenir soit du dispositif d'acquisition (camera, amplificateur, quantification,..), soit de la scène elle-même (poussières, rayures,..). Elles constituent des perturbations qui affectent la qualité de la segmentation et sont généralement désignées sous le terme de *bruit d'image*. Le bruit est un phénomène de brusque variation d'un pixel par rapport à ses voisins. Dans une image, on cherche à diminuer l'amplitude de ces perturbations, sans toucher aux zones de transitions.

L'échelle spatiale de fluctuation est relativement faible par rapport aux dimensions des régions. Le bruit est donc plutôt de type haute fréquence. Dans la plupart des cas, le bruit d'image est considéré comme étant aléatoire, centré et additif. Le prétraitement se ramène alors à un problème de traitement de signal, c'est-à-dire retrouver par filtrage, les niveaux d'intensité lumineuse de chacune des régions.

Le filtrage d'image consiste à recalculer la valeur de chaque pixel en analysant les radiométries sur un voisinage, par exemple pour lisser l'image ou au contraire pour accentuer les contrastes.

I.8 Le filtrage

I.8.1 Filtrage linéaire : Le filtrage est la convolution d'une image $I(x, y)$ avec une fonction

$F(x, y)$ qui s'appelle réponse impulsionnelle du filtre. Dans le cas discret, les domaines de I et de F sont bornés. Le domaine de I est de $[-n/2, +n/2]$, et celui de F est de $[-k/2, +k/2]$.


Avec n^2 la taille de l'image et k^2 la taille de la fenêtre de traitement.

I.8.1.1 Filtre passe-bas

Ces filtres ont généralement pour but de réduire les parasites (bruits de mesure). Ils agissent par moyenne sur un voisinage et atténuent donc les détails, par conséquent, ils provoquent un adoucissement de contour.



Image originale.



Après filtrage passe bas.

Figure11 : filtrage passe-bas

I.8.1.2 Filtre passe-haut

Ces filtres ont pour but d'augmenter le contraste et de mettre en évidence les contours en atténuant la composante basse fréquence.



Image originale.



Après filtrage passe haut.

Figure12 : filtrage passe-haut

I.8.1.3 Filtre passe-bande

Cette opération est une dérivée du filtre passe-bas. Elle consiste à éliminer la redondance d'information entre l'image originale et l'image obtenue par filtrage passe-bas, seule la différence entre l'image source et l'image traitée qui est conservée.

I.8.2 Filtrage non linéaire

On désigne par filtre non linéaire un opérateur qui remplace la valeur de chaque pixel par une combinaison non linéaire des valeurs de ses pixels voisins.

Le but principal du filtrage non linéaire est d'apporter des solutions aux limites des filtres linéaires en utilisant plusieurs techniques comme les statistiques d'ordre (basée sur le classement des valeurs des pixels voisins) etc. On distingue plusieurs types de filtres non linéaires :

I.8.2.1 Filtre d'ordre

Les filtres d'ordres procèdent en remplaçant les valeurs de chaque pixel par la valeur qui occupe un certain rang lorsqu'on trie les valeurs observées dans un certain voisinage du pixel. Il existe deux types de filtre d'ordre

- Filtrage par la médiane : la valeur du point centrale d'une fenêtre de l'image est affectée par celle de ses voisins en classant les valeurs de cette dernière par ordre croissant (en prenant la valeur médiane).

- Filtrage par le plus proche voisin radiométrique : dans ce cas, on attribue au point central la moyenne des K pixels voisins dont les valeurs radiométrique sont plus proches de la sienne.

I.8.2.2 Filtre de position

Ce filtre utilise des voisinages 5*5, le sous voisinage le plus homogène est sélectionné et son niveau de gris moyen est affecté au point central.

I.8.2.3 Filtre médian

Ce filtre remplace la valeur de chaque pixel par la valeur médiane du voisinage. Il produit un adoucissement de l'image comme un effet passe bas.

Le filtre médian garde la netteté de l'image pour les éléments de dimension importante par rapport au noyau du filtre, mais élimine les détails fins de manière irrémédiable.

I.9.Rehaussement de contraste

Rehausser le contraste de l'image consiste à diminuer l'étendue de la zone de transition sans affecter l'intensité moyenne des régions situées de part et d'autre. On limite ainsi le risque de fusion intempestive de régions distinctes lors de la phase de segmentation. L'opérateur de rehaussement de contraste devra, si possible, réduire le bruit dans les zones stationnaires et éviter les phénomènes de dépassement. Ce type d'opérateur est réalisable au moyen de méthodes linéaires ou non linéaires.

Discussion

Ce chapitre est centré sur tout ce qui concerne le domaine du traitement d'image. Ce dernier est le processus qui prend une image en entrée et produit une autre image, qui est le résultat d'une opération de transformation qui vise à satisfaire la vision humaine. On a essayé aussi de donner un aperçu sur le principe de fonctionnement des opérateurs de traitement d'image les plus utilisés, tel que : la modification d'histogramme, l'amélioration des contrastes, le filtrage et d'autres. Le prochain chapitre abordera les principales techniques de segmentation

Chapitre II

Segmentation d'images texturées

Préambule

La segmentation est une étape primordiale dans toute opération d'analyse d'images et la vision par ordinateur. Elle est réalisée avant les étapes d'analyse et de prise de décision dans plusieurs processus de traitement d'image. Son but est l'extraction à partir d'une image numérique, des informations « utiles » qui pourront permettre de localiser et de délimiter les entités présentes dans l'image.

La segmentation est considérée comme un problème difficile, à cause de la diversité des images existantes de nos jours (photos numériques, images radar, images satellitaires, images médicales ...etc.). Actuellement, il n'y a pas de méthode de segmentation efficace sur tout type d'images. Les chercheurs ont développé une multitude de méthodes de segmentation, selon le domaine d'application. Les experts en traitement d'images tentent de créer des méthodes de segmentation automatiques, indépendantes de l'être humain, c'est ce qu'on peut appeler une segmentation non-supervisée, mais dans certains cas, une intervention de la part d'un spécialiste s'avère être indispensable, ce sont les méthodes supervisées et semi-supervisées. Dans ce qui suit, nous introduiront la notion de segmentation, et voir les différentes méthodes existantes. Cependant, il est plus judicieux d'aborder dans un premier temps la notion de textures et les méthodes de leur analyse.

II .1Définition de la texture

Par définition, la texture est une répétition spatiale d'un même motif dans différentes directions de l'espace. Cette définition est limitative car elle caractérise l'objet indépendamment d'un observateur humain. La notion de texture est utilisée pour traduire un aspect homogène de la surface d'un objet sur une image. La texture se manifeste donc par une information visuelle qui permet de la décrire qualitativement à l'aide des adjectifs suivants : grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière et irrégulière. De nombreuses études psycho-visuelles ont été faites sur la discrimination de texture par le système visuel humain. Une conjecture importante et valide dans beaucoup de cas est que l'œil humain ne peut discerner instantanément deux textures dont les statistiques du second ordre sont identiques. Cependant, il existe des cas où des textures ayant les mêmes statistiques du second ordre sont néanmoins discriminables sur la base de propriétés locales.

Haralick [1] élargit la définition en décrivant une texture comme un phénomène à deux dimensions : la première concernant la description d'éléments de base ou primitives (le motif) à partir desquels est formée la texture ; la deuxième dimension est relative à la description de l'organisation spatiale de ces primitives. Pour Unser[2], la texture se présente comme une structure disposant de certaines propriétés spatiales homogènes et invariantes par translation.

Une autre approche serait encore de définir la texture à partir de deux types d'informations essentielles que comporte l'image :


- 1) Les contours de types monodimensionnels, qui marquent les frontières entre régions homogènes.
- 2) L'aspect de surface, de type bidimensionnel, qui définit les régions homogènes.
- 3) Cependant, la description d'une texture peut s'avérer erronée à une autre échelle d'observation, c'est-à-dire en changeant la résolution.

En pratique, on distingue deux grandes classes de textures, qui correspondent à deux niveaux de perception.

II.1.1 Textures périodiques (macro textures) : qui présentent un aspect régulier, sous formes de motifs répétitifs spatialement placés selon une règle précise (ex : peau de lézard, mur de brique), donc une approche structurelle est déterministe.



Mur de brique




peau de lézard

Figure 13 : exemple de texture périodique

II.1.2 Textures stochastiques (micro textures) : qui présentent des primitives (microscopiques) distribuées de manière aléatoire (ex : bois, laine tissée, herbe) d'où une approche probabiliste cherchant à caractériser l'aspect anarchique et homogène.




Bois



Herbe

Figure 14 : exemple de texture stochastique

II.1.2 texture hybride (directionnelle) : c'est une concaténation des deux types précédent où on peut trouver par exemple la texture composée d'un seul motif de base réparti aléatoirement (ex : sable, canevas).



Sable



Canevas

Figure 15 : exemple de texture hybride

D'après Gagalowicz[3] : la texture est une région de l'image pour laquelle on peut définir une fenêtre de dimension minimale à travers laquelle l'observation se traduit par une impression visuelle identique pour toutes les translations possibles de cette fenêtre à l'intérieur de la région considérée [4].

II .2Méthodes d'analyse de textures

Après la phase de prétraitement, l'extraction d'attributs d'une texture, ou les paramètres la caractérisant, constitue une étape fondamentale afin de segmenter une image en régions ayant chacune, des propriétés statistiques et visuelles différentes.

Vu la difficulté d'une définition précise de la texture, plusieurs approches ont été élaborées ces dernières années pour identifier cette opération. Nous donnerons ci-après quelques méthodes essentiellement utilisées.

Elles sont de nature :

- Structurelles ou déterministes.
- Spatio-fréquentielle.
- Statistiques.

II.2.1Extraction des données structurelles

Les méthodes structurelles cherchent à extraire des textures, les primitives des textures et leur localisation.

Ces méthodes s'avèrent donc adaptées aux macrotextures (les textures à grains larges), ou une structure spatiale forte se dégage par l'intermédiaire d'un motif plus au moins répétitif.

Les méthodes basées sur cette approche procèdent d'une part, à l'extraction de ces primitives par, soit la technique de croissance de région, soit la technique de détection de contours, et d'autre part, à la définition des règles de placement de celles-ci, qui peuvent être obtenues par la fonction d'auto-corrélation, la transformée de Fourier, etc.

II.2.2Extraction de données spatio-fréquentielles

Initialement, une approche fréquentielle a été adoptée par l'intermédiaire d'une décomposition du spectre de Fourier de l'image en question. Pour cette méthode, l'information de localité spatiale est perdue.

Ainsi, vu cette perte de localisation, ces méthodes fréquentielles seront abandonnées.

Les méthodes spatio-fréquentielles permettent maintenant d'obtenir une bonne localisation à la fois dans le domaine spatial et fréquentiel.

Ces méthodes s'appuient sur les opérateurs de filtrage appliqués sur l'image. Parmi les méthodes de caractérisations des textures les plus répandues, on trouve la méthode mise en œuvre par les masques directionnels de Laws[5], celle-ci consiste en la modélisation des champs récepteurs des cellules de cortex-strié de l'œil humain, et les filtres de types passe bande orientés comme les filtres basés sur la fonction de Gabor 2D

II.2.2.1Méthode basée sur le spectre de puissance

La première approche fréquentielle a été élaborée par Weszka & all [6]. Elle est basée sur le calcul du spectre de puissance de l'image $f(x, y)$. Cette méthode, basée sur le domaine de Fourier présente un inconvénient dû à la perte d'information de la localisation spatiale dans l'image.

II.2.2.2 Masques de Laws

Laws[5] a étudié un ensemble de masque de détection de contour, de bords et de taches pour caractériser les textures par rapport à des propriétés statistiques estimées sur les images [5]. Sur chaque image, après convolution avec les masques, est estimée une énergie locale pour chaque pixel. Les propriétés statistiques (moyenne, variance) de l'énergie dans un voisinage sont estimées pour caractériser les différentes textures.

Les masques de Laws sont dérivés de noyaux à 3 composantes qui représentent la moyenne centrale pondérée, $L3 \equiv (1, 2, 1)$, la différence symétrique du premier ordre, $E3 \equiv (-1, 0, 1)$ et du deuxième ordre, $S3 \equiv (-1, 2, -1)$. D'autres masques à 5 coefficients sont calculés par convolution entre les masques à 3 coefficients, comme par exemple :

$$L5 \equiv (1, 4, 6, 4, 1) = L3 * L3,$$

$$S5 \equiv (-1, 0, 2, 0, -1) = L3 * S3 = E3 * E3,$$

$$E5 \equiv (-1, -2, 0, 2, 1) = L3 * E3,$$

$$R5 \equiv (1, -4, 6, -4, 1) = S3 * S3,$$

Les trois premiers font respectivement une moyenne centrale, une différence symétrique du deuxième ordre et une différence symétrique du premier ordre. Une différence du premier ordre (masqueE5) correspond à une détection de bords, une, du deuxième ordre (masqueS5) correspond à une détection des taches, tandis que le masque R5 détecte les ondulations.

| L3L3 | | | L3E3 | | | L3S3 | | |
|------|----|----|------|---|----|------|----|----|
| 1 | 2 | 1 | -1 | 0 | 1 | -1 | 2 | -1 |
| 2 | 4 | 2 | -2 | 0 | 2 | -2 | 4 | -2 |
| 1 | 2 | 1 | -1 | 0 | 1 | -1 | 2 | -1 |
| E3L3 | | | E3E3 | | | E3S3 | | |
| -1 | -2 | -1 | 1 | 0 | -1 | 1 | -2 | 1 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 1 | 2 | 1 | -1 | 0 | 1 | -1 | 2 | -1 |
| S3L3 | | | S3E3 | | | S3S3 | | |
| -1 | -2 | -1 | 1 | 0 | -1 | 1 | -2 | 1 |
| 2 | 4 | 2 | -2 | 0 | 2 | -2 | 4 | -2 |
| -1 | -2 | -1 | 1 | 0 | -1 | 1 | -2 | 1 |

Table.1 : Différents masques de Laws 3x3

| L5E5 | | | | | E5S5 | | | | |
|------|-----|----|----|----|------|-----|-----|-----|----|
| -1 | -2 | 0 | 2 | 1 | -1 | 0 | 2 | 0 | -1 |
| -4 | -8 | 0 | 8 | 4 | -2 | 0 | 4 | 0 | -2 |
| -6 | -12 | 0 | 12 | 6 | 0 | 0 | 0 | 0 | 0 |
| -4 | -8 | 0 | 8 | 4 | 2 | 0 | -4 | 0 | 2 |
| -1 | -2 | 0 | 2 | 1 | 1 | 0 | -2 | 0 | 1 |
| L5S5 | | | | | R5R5 | | | | |
| -1 | 0 | 2 | 0 | -1 | 1 | -4 | 6 | -4 | 1 |
| -4 | 0 | 8 | 0 | -4 | -4 | 16 | -24 | 16 | -4 |
| -6 | 0 | 12 | 0 | -6 | 6 | -24 | 36 | -24 | 6 |
| -4 | 0 | 8 | 0 | -4 | -4 | 16 | -24 | 16 | -4 |
| -1 | 0 | 2 | 0 | -1 | 1 | -4 | 6 | -4 | 1 |

Table.2 : Les masques de Laws 5x5

II.2.3Extraction de données statistiques

Ces approches correspondent à une vision microscopique des textures. Elles s'appuient sur la théorie des processus aléatoires. Dans cette approche, on cherche à caractériser la distribution spatiale des niveaux de gris.

Parmi ces méthodes, nous citons :

II.2.3.1 Analyse texturale par cooccurrence :

Les matrices de cooccurrence permettent d'estimer des propriétés des images relatives à des statistiques de second ordre. Cette approche est la plus utilisée pour extraire des caractéristiques de textures.

Pour une translation t , la matrice de cooccurrence MC_t d'une région R est définie pour tout couple de niveau de gris (i, j) par :

$$MC_t = \text{card} \{ (s, s+t) \in R^2 \mid I(s)=i, I(s+t)=j \} \quad (\text{II.1})$$

$MC_t(i, j)$ est donc le nombre de couples de sites $(s, s+t)$ de la région considérée, séparés par le vecteur de translation t et tel que s a pour niveau de gris i et $s+t$ a pour niveau de gris j . Pour une image I , quantifiée sur N_g niveaux de gris, la matrice MC_t est une matrice $N_g * N_g$. En pratique, on réduit généralement cet ensemble de niveaux de gris à 8 ou 16 valeurs [7].

II.2.3.2 Méthode de la décomposition morphologique

La morphologie mathématique considère l'image comme un ensemble d'objets où chaque objet constitue un sous ensemble de l'espace dans lequel il est défini. La forme de l'image est comparée à une forme élémentaire appelée structurant.

II.2.3.3 Matrices de longueurs de plages

Il s'agit ici de représenter une texture par un ensemble de segments de droite de taille maximale et de luminance constante. Par la suite, on extrait des paramètres qui dépendent de la longueur des plages, de la luminance et de l'orientation des segments.

Une plage de niveau de gris (isosegment) est un ensemble de pixels consécutifs, dans une direction donnée, ayant le même niveau de gris. La longueur d'une plage est le nombre de pixels dans cet ensemble [7].

II.3 Segmentation d'images

La segmentation selon le dictionnaire Larousse est la division d'une unité anatomique en plusieurs éléments. En imagerie, la segmentation d'image est la division d'une image en zones homogènes afin de séparer les divers composants visibles et de les identifier ou bien c'est effectuer une partition de cette image en régions, telle que chacune d'elles possède au moins une caractéristique que ne possèdent pas les régions voisines. Mathématiquement, nous pouvons la modéliser de la façon suivante :

Soit une image I , la segmentation consiste à créer une partition de l'image I en sous ensembles R_i connexes ou régions :

$$\left\{ \begin{array}{l} \forall i R_i \neq \emptyset \\ \forall i, j; i \neq j R_i \cap R_j = \emptyset \\ I = \cup R_i \end{array} \right. \quad \begin{array}{l} \text{(II.2)} \\ \text{(II.3)} \\ \text{(II.4)} \end{array}$$

En d'autres termes, les conditions suivantes doivent être vérifiées :

- Chaque pixel doit appartenir à une classe.
- Les régions doivent être homogènes.
- Les régions doivent être deux à deux disjointes.

➤ **Segmentation d'images texturées**

L'analyse des textures peut être décrite comme une chaîne de processus : extraction des attributs, sélection des caractéristiques pertinentes et catégorisation supervisée ou non supervisée.

II.4 Les méthodes de segmentation de textures

II.4.1 Segmentation par région

Les approches régions recherchent la similarité. Elles considèrent une région comme un ensemble de pixels connexes dont les attributs de textures sont proches les uns des autres. Cependant la localisation des frontières reste généralement peu précise.

Les techniques de traitement d'images pour la segmentation par région se décomposent globalement suivant trois approches [8]

- **Méthode par séparation (Quad-Tree)** : elle consiste à tester un critère d'homogénéité sur une zone large de l'image. Si le critère est respecté, la segmentation est terminée. Si non, on décompose la zone en quatre zones plus petites et on réapplique la méthode sur chaque petite zone, jusqu'à ce que le critère soit validé. Cela correspond à réaliser un arbre des zones segmentées.
- **Méthode par fusion** : inversement à la méthode précédente, elle consiste à explorer l'image par petites zones et à les faire croître, jusqu'à ce que le critère soit validé.
- **Méthode par séparation/fusion** : elle combine les deux méthodes précédentes. On applique d'abord la division par Quad-Tree, puis on parcourt l'arbre dans le sens inverse en fusionnant les régions satisfaisant le critère d'homogénéité.

Les techniques de segmentation par région peuvent être combinées avec une quantification des données par prototypes. Le prototypage des zones est réalisé par exemple, à l'aide de techniques de quantification vectorielle comme l'algorithme des K-moyennes.

Cette méthode itérative consiste à produire un nombre fixé à l'avance (k) de prototypes (classes) pour représenter une distribution donnée sur un plus grand nombre d'échantillons. Ce nombre de prototypes k est donné normalement de façon heuristique ou expérimentale.

Cette méthode de segmentation est utilisée pour divers types d'attributs de textures, comme ceux montrés par exemple dans [9].

II.4.2 Méthodes de détection de contours

L'approche locale de détection de contour consiste à balayer l'image avec une fenêtre d'analyse. Un opérateur est appliqué à chaque pixel de l'image afin de détecter les transitions significatives au niveau de l'attribut choisi.

Notons que les méthodes classiques de détection de contours ne peuvent pas être directement utilisées pour l'image texturée, puisque les pixels dans la texture sont représentés par plusieurs attributs. La détection de contours dans une image texturée consiste à rechercher les discontinuités importantes des attributs de texture. Pour intégrer les informations spatiales, les opérateurs de dérivation sont souvent utilisés [10].

L'approche contour n'aboutit pas directement à une segmentation car les contours détectés ne sont pas toujours connexes. Il existe cependant des techniques permettant d'obtenir des

contours fermés. Dans ce cas, on observe une parfaite dualité entre les contours et les régions.

Comme les opérateurs de dérivation sont très sensibles au bruit, des images bruitées doivent être préalablement lissées. Un grand nombre d'opérateurs gradient ont été proposés. Ils se distinguent entre eux principalement par le choix du filtre de lissage. Le lissage et la dérivation sont en pratique réunis dans un seul filtre. Des opérateurs optimaux ont été proposés par un ensemble de chercheurs tel que Canny et Derriche [10] [11].

II .4.3 Les méthodes markoviennes pour la segmentation

Les modèles de Markov sont souvent utilisés pour la segmentation d'image texturée. Dans ce cas, les attributs de textures disponibles sont modélisés par les champs de Markov qui vont représenter chaque classe de texture. Les meilleurs appariements entre les modèles de Markov et les classes de textures sont obtenus par l'algorithme des K-moyennes pour réaliser la segmentation.

En [12], cette méthode de segmentation est utilisée avec des attributs de textures extraits par les filtres de quadrature en miroir à travers une décomposition d'images texturées en bandes de fréquence et les mesures statistiques du premier ordre sur chaque bande.

D'autres travaux ont également utilisé les champs de Markov pour réaliser la segmentation de textures [13, 14]. Dans [15], les caractéristiques de textures utilisées pour la segmentation étaient originaires de filtrages gaussiens et de filtrages de Gabor. Dans [16], les analyses globales et locales de statistiques spatiales du premier ordre et d'ordres supérieurs sont utilisées pour réaliser une segmentation non supervisée de textures par des champs markoviens. [17]

II.4.4 Segmentation basée sur les pixels (approche classification)

La segmentation d'image par classification consiste à partitionner l'image en un ensemble de classe, telle que chaque classe regroupe des pixels ayant des vecteurs d'attributs de texture aussi similaire que possible ; et que les classes soient éloignées (en terme d'attributs) que possible les une des autre. Cette méthode forme un nuage de points dans l'espace des attributs. La classification consiste à retrouver ces nuages de points qui correspondent aux classes de pixels présentes dans l'image. La dimension de cet espace de représentation est égale au nombre d'attributs de texture. Parmi ces méthodes, la méthode des K-Means est très utilisée et nous la retenons comme méthode de classification dans notre approche.

➤ **Méthode de K-means :**

L'algorithme des centres mobiles considère un centre de gravité pour chaque classe ; il consiste à partitionner l'ensemble des pixels de l'image en un nombre de classe prédéterminé par l'utilisateur.

Pour chaque classe, un pixel est sélectionné de façon aléatoire parmi l'ensemble des pixels de l'image, afin de constituer son centre de gravité initial. Chaque pixel de l'image est ensuite affecté à la classe dont le centre de gravité est le plus proche. Ainsi, on obtient une première partition de l'ensemble des pixels. Une fois que tous les pixels de l'image ont été affectés à leurs classes respectives, le centre de gravité de chaque classe réactualisé et le processus est réitéré jusqu'à ce que les centres de gravités ne changent pas.

La méthode de K-means converge vers un minimum local de la somme des distances euclidiennes entre les points de chaque classe et son centre de gravité. Ce minimum ne correspond pas nécessairement au minimum global recherché et dépend de la position initiale des centre de gravité.

Malgré cet inconvénient, la méthode de K-means a été abondamment utilisée pour la segmentation d'images texturées.

II .4.5La segmentation coopérative

Comme les approches régions et contours présentent toutes les deux des avantages et des inconvénients. Les chercheurs ont essayé de trouver un compromis entre les deux, et ont donné naissance à ce qu'on appelle la segmentation coopérative. Son principe est de tirer profit de chacune des approches pour un meilleur résultat de segmentation [18].

Voici un organigramme qui illustre les différentes étapes d'analyse de textures .

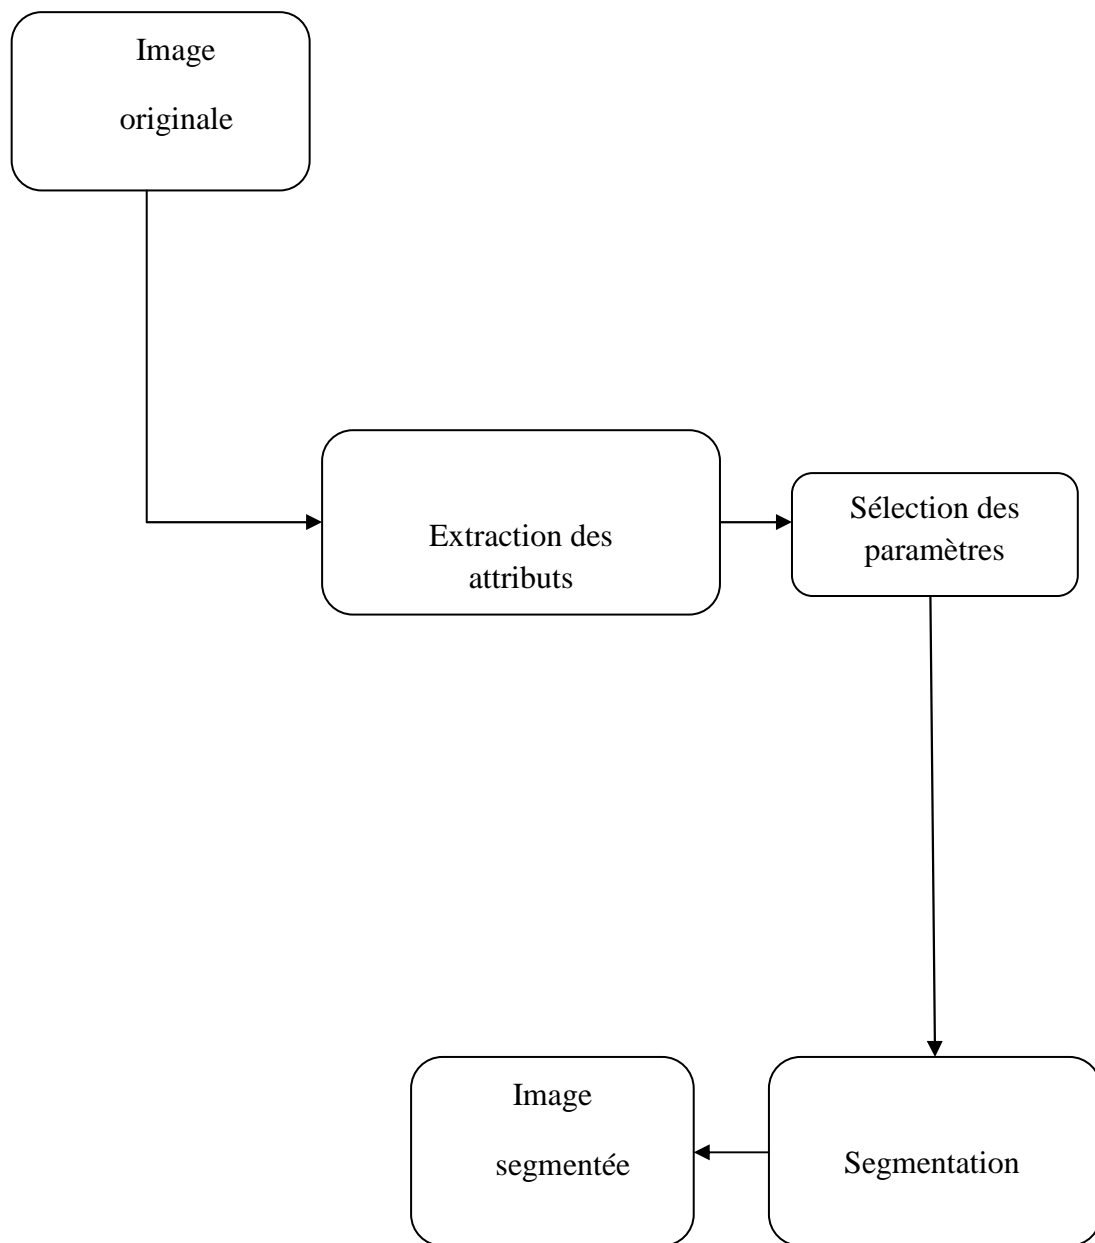


Figure 16 : Etapes de segmentation d'une image

Discussion

Nous avons essayé dans ce chapitre d'introduire la notion de segmentation. La diversité des techniques existantes nous donne à peu près une idée sur la difficulté du problème.

Principalement, les méthodes de segmentation sont classées en deux catégories : les méthodes orientées contours et les méthodes orientées régions.

Les méthodes orientées contours se basent sur la dissimilarité dans l'image, ou sur la variation d'intensité entre les pixels, c'est-à-dire là où le changement d'intensité est brusque. Les méthodes orientées régions quand à elles, se basent sur la similarité dans l'image, et tentent de partager l'image en régions homogènes. Parmi ces méthodes nous trouvons : la segmentation par fusion de régions, division de régions, etc.

Ces deux approches ayant toutes les deux des avantages et des inconvénients, les chercheurs les ont combinées et ont créé ce qu'ils ont appelé la segmentation coopérative.

Les images naturelles présentent souvent un aspect complexe d'où la nécessité de les analyser en s'appuyant sur les techniques multi-résolutions. Le prochain chapitre introduira ces différentes notions.

Chapitre III

Ondelettes et multi-résolution

Préambule

La transformée de Fourier est un outil fondamental aussi bien en mathématique qu'en physique et traitement de signal, qui consiste à décomposer le signal f sur des fonctions très localisées en fréquence et non localisées en espace. Mais cette dernière ne fournit pas l'information en temps et en fréquence. Elle nous renseigne sur les composantes spectrales du signal mais non pas sur les variations de ces dernières dans le temps. L'analyse de Fourier est peu adaptée à l'étude des signaux non-stationnaires où des événements imprévisibles apparaissent. Ces signaux sont rencontrés beaucoup plus souvent que les signaux stationnaires. Pour leur étude, il faudra donc employer une autre méthode d'analyse qui tient compte de l'information temporelle du signal. C'est la raison pour laquelle que la transformée de Fourier à fenêtre glissante est apparue afin de remédier à ce problème; c'est un outil temps-fréquence qui restreint l'existence du signal autour d'une position τ grâce à une fenêtre d'analyse $g(t - \tau)$, puis prend sa transformée de Fourier.

Dans la pratique, on a souvent des signaux qui ont un comportement fréquentiel dynamique, caractérisé par des fréquences hautes de courte durée, suivi par des composantes basses fréquences de longue durée. Le principe de la transformée de Fourier fenêtrée, basé sur l'analyse de tout le signal avec la même précision temps-fréquence, n'est pas approprié pour ce genre de signaux. Un autre outil puissant permet de résoudre ce problème et porte le nom de la transformée en Ondelettes.

III.1 Transformée de Fourier

La transformée de Fourier est un outil qui sert à mesurer la fréquence d'un signal. Son principe repose sur le fait que toute fonction périodique peut être représentée comme la somme d'une série de sinus et de cosinus pour laquelle on fait varier d'une part les amplitudes en les multipliant par des coefficients, et d'autre part les phases en les décalant de manière à ce qu'elles s'additionnent ou se compensent.

$$F(w) = \int_{-\infty}^{+\infty} f(t)e^{-iwt} dt$$

(III.1)

Cependant, l'analyse de Fourier, de par sa nature, a montré ses limitations : son calcul nécessite la connaissance de toute l'histoire temporelle du signal. De plus, dans une transformée de Fourier, l'information sur le temps est présente (la transformée inverse est donc possible), mais elle est cachée dans les phases : elle est en pratique impossible à extraire. On en est donc réduit à étudier un signal soit en fonction du temps, soit en fonction des fréquences qu'il contient, sans possibilité de conjuguer les deux analyses.

La définition de la TF inverse est donnée par la formule suivante:

$$f(t) = \int_{-\infty}^{+\infty} F(w)e^{iwt} dw$$

(III.2)

On peut utiliser la transformée de Fourier pour extraire des informations fréquentielles d'une image, toutefois le principal problème de la transformée de Fourier est son manque de résolution temporelle. Cela signifie simplement que si on est effectivement capable de détecter toutes les fréquences qui apparaissent dans un signal, on est en revanche incapable de déterminer à quel moment elles se produisent dans le signal. Il existe une transformée de Fourier plus «locale» donnant des informations mieux localisées, il s'agit de la transformée de Fourier à Fenêtre glissante (TFFG).

III.2 La transformée de Fourier à fenêtre glissante

Afin d'analyser temporellement et fréquentiellement un signal $f(t)$, D. Gabor [19] a introduit en 1946 la transformée de Fourier à fenêtre glissante (TFFG) ou short time Fourier transform (STFT). Cette méthode, pouvant être adaptée aux signaux non-stationnaires, est très proche de l'analyse spectrale: on définit une fenêtre qui sera utilisée comme masque sur le signal, et dans laquelle on considère que le signal est localement stationnaire, puis on décale cette fenêtre le long du signal afin de l'analyser entièrement. La fenêtre est représentée par une fonction gaussienne $G(t)$:

$$G_{a,b}(t) = e^{-iat}G(t - b) \quad a, b \in \mathcal{R}$$

(III.3)

Où a représente le facteur d'échelle, et b le facteur de translation.

On constate que le terme $G(t - b)$ de l'équation ci-dessus (III.3) est indépendant de a , ce qui signifie que l'enveloppe de la fenêtre glissante est constante : nous aurons donc une résolution fixe sur toute la durée du signal.




Figure 17 : Fenêtre de Gabor décalée d'un temps τ

Ainsi, l'étude d'un signal avec la transformée de Gabor permet d'obtenir à la fois une information sur le temps et sur la fréquence mais la résolution d'analyse est fixée par le choix de la taille de l'enveloppe : si la fenêtre est trop petite, les basses fréquences n'y seront pas contenues, et si la fenêtre est trop grande, l'information sur les hautes fréquences est noyée dans l'information concernant la totalité de l'intervalle contenu dans la fenêtre [17].

III.3 La transformée en ondelettes

Comme on l'a vu pour plusieurs cas, on cherche une localisation temporelle du comportement fréquentiel d'un signal. La transformée en Ondelettes (comme celle de Fourier) permet un passage d'une représentation à une autre. De plus, nous pourrions dire que les ondelettes comme la transformée à fenêtres permettent aussi de mesurer les variations dans le temps des composantes fréquentielles (spectrales) d'un signal.

III.3.1 Définition et propriétés

Une ondelette est une forme d'onde qui a une valeur moyenne nulle et une durée limitée. La transformée en ondelettes est une représentation multi-résolution, qui exprime les variations d'un signal à différentes résolutions. Une Ondelette Ψ est une fonction oscillante, comme les fonctions sinus et cosinus, mais localisée. Deux opérations importantes

appliquées à la fonction d'ondelette nous permettent de générer une infinité de variations de celle-ci. La translation qui correspond au déplacement de l'ondelette le long de l'axe des x , la deuxième opération est la dilatation. Cette notion est donnée par la formule générale d'une ondelette :

$$\Psi_{a,b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (a, b) \in \mathbb{R}, \quad a > 0 \quad (\text{III.4})$$

Le paramètre ' b ' est relatif à la translation tandis que ' a ' est relatif à la dilatation.

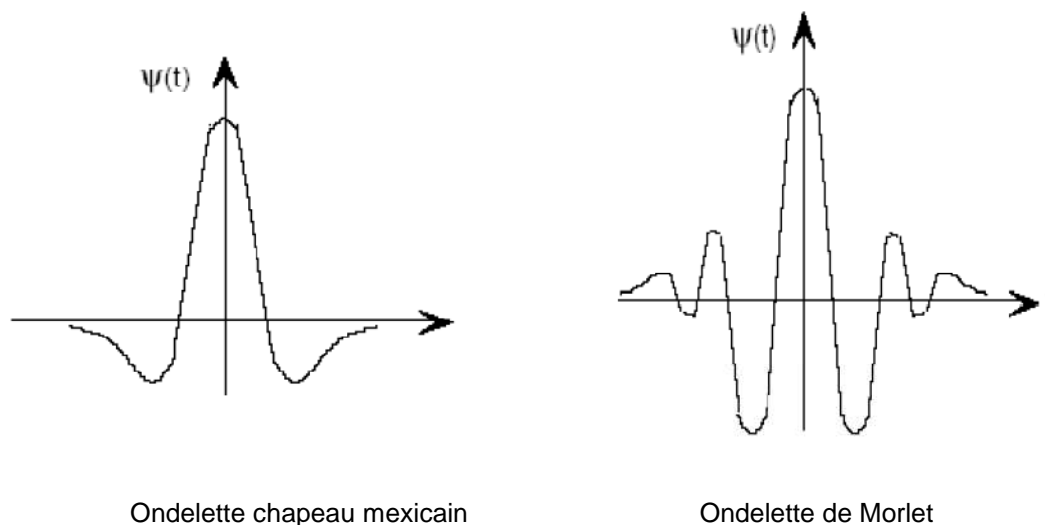


Figure 18 : exemples d'ondelettes

L'idée était d'analyser le signal avec des fonctions élémentaires « Ondelettes » construites à partir d'une fonction Ondelette mère, elle est conçue pour osciller (comme une onde) mais limitée dans le temps (petite onde), et doit être bien localisée aussi bien en temps qu'en fréquence. Ceci se traduit par une condition dite d'admissibilité qui est la suivante :

Soit Ψ une fonction non nulle de $L^2(\mathbb{R})$ et $\widehat{\Psi}$ sa transformée de Fourier :

$$C_{\Psi} = \int_{-\infty}^{+\infty} \left| \widehat{\Psi}(w) \right|^2 \frac{dw}{w} < +\infty$$

(III.5)

Si la relation (III.5) est vérifiée, alors Ψ est dite admissible, on appelle également Ψ ondelette analysante.

En pratique, le choix d'une ondelette analysante se fait en fonction du but recherché.

Des critères supplémentaires tels que la régularité, symétrie, décroissance rapide à l'infini peuvent être nécessaires. Parmi les types d'ondelettes qui existent, on a: l'ondelette de HAAR, Les ondelettes de I. Daubechies [20].

III.3.2 La transformation en ondelettes continues

La transformée en ondelettes continue utilise des translations et des dilatations de la fonction ondelette mère durant tout l'intervalle du temps de manière continue.

Cette transformée a été introduite par Morlet et son équipe. Elle porte son nom.

La transformée en ondelette d'un signal f s'écrit :

$$(III.6) \quad \text{TO} \quad (a; b) = \frac{1}{\sqrt{a}} \int_{\mathcal{R}} \bar{\Psi} \left(\frac{x-b}{a} \right) dt$$

Avec $\left\{ \begin{array}{l} (a, b) \in \mathcal{R}^2 \\ a > 0 \end{array} \right.$

$\bar{\Psi}$ représente le complexe conjugué de Ψ

Cette transformation est en théorie infiniment redondante puisque l'ondelette est tradlatée de manière continue. Cependant, il existe des méthodes pour diminuer cette redondance et l'une de ces méthodes consiste en l'emploi de la transformée en ondelettes discrète.

III.3.3 La transformée en Ondelettes Discrète

Le facteur d'échelle a et le paramètre de translation b sont des réels, on peut les faire varier continument, la transformation en ondelette est continue et donc redondante ; c'est-à-dire que l'on obtient plus de coefficient d'ondelette qu'il n'en est nécessaire pour décrire le signal de manière complète. Le pavage temps-fréquence obtenu suggère une méthode de discrétisation exponentielle pour les échelles et pour le temps.

Comme le pas de translation à l'échelle a est $\frac{b}{a}$. On posera :

$$a = a_0^m \text{ et } b = nb_0 a_0^m \text{ avec } a_0, b_0 \in Z$$

D'où découle la transformée en ondelettes discrète

$$\text{TO D} \quad f(m, n) = a_0^{-\frac{m}{2}} \int_{-\infty}^{+\infty} f(t) \Psi(a_0^{-m} t - nb_0) dt = \langle f(t), \Psi_{m,n}(t) \rangle$$

(III.7)

La notion $\langle f, g \rangle$ représente le produit scalaire :

$$\langle f, g \rangle = \int_{-\infty}^{+\infty} f(x)g(x)dx \quad (\text{Pour les fonctions réelles}).$$

En 1985, Meyer découvrit que si on choisissait des opérateurs de dilatation et de translation dyadiques ($a_0 = 2, b_0 = 1$), on obtiendrait une représentation non redondante de l'information. La nouvelle fonction analysante est:

$$\Psi_{m,n} = a_0^{-\frac{m}{2}} \Psi(a_0^{-m} t - nb_0) \quad m, n \in Z$$

(III.8)

La transformée en ondelette est donc obtenue par échantillonnage des coefficients d'échelle et de temps sur la grille dyadique, et la nouvelle famille des ondelettes a pour expression :

$$\Psi_{m,n} = 2^{-\frac{m}{2}} \Psi(a^{-m} t - n) \quad m, n \in Z$$

(III.9)

Remarque : c'est important de souligner que c'est la transformée qui est discrète et non pas l'ondelette qui reste une fonction continue.

III.3.4 Bases orthonormées d'ondelettes

La découverte en 1985 des bases orthonormées d'ondelettes fût un tournant décisif dans la théorie des ondelettes. Y. Meyer montre dans [21] qu'il existe des familles d'ondelettes dénombrables $(\Psi_{j,k})_{(j,k) \in Z^2}$ formant des bases orthonormées de $L^2(R)$. [22]

La base d'ondelettes étant orthonormée, les coefficients d'ondelettes $DWT(j, k)$ calculés par l'équation suivante sont décorrélés entre eux.

$$DWT(j, k) = \int_{-\infty}^{+\infty} f(t) \bar{\Psi}_{j,k}(t) dt \quad \text{Ou} \quad DWT(j, k) = \langle f(t), \Psi_{j,k}(t) \rangle$$

(III.10)

Le signal f peut s'écrire sous la forme :

$$f(t) = \sum_{j \in Z} \sum_{k \in Z} DWT(j, k) \Psi_{j,k}(t)$$

(III.11)

La formule (III.11) nous permet d'assurer une reconstruction exacte du signal x . Un outil fondamental de la construction de bases d'ondelettes orthonormées introduit par Y. Meyer [21] et S. Mallat [23] est l'analyse multi-résolution [22].

III.4 Analyse multi-résolution

L'analyse multi-résolution (AMR) est en quelque sorte la formalisation mathématique du phénomène suivant : lorsqu'on observe un objet, suivant les distances à lesquelles on se trouve, on voit plus ou moins de détails, alors que l'objet est le même.

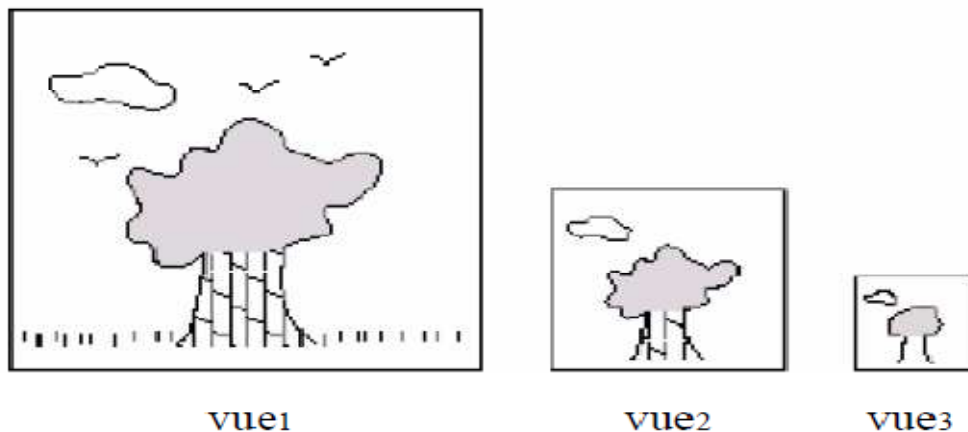


Figure 19 : le schéma illustre le principe de multi-résolution

On remarque, dans ce schéma, la disparition progressive de détails du paysage, d'abord les oiseaux et l'herbe puis la forme du tronc. On peut dire que les espaces de représentation de chaque vue de l'objet initial ne sont pas les mêmes, d'où cette présence ou absence de détails. Ces approximations successives utilisent alors différentes résolutions, d'où le nom d'analyse multi-résolution. A une résolution grossière, les détails correspondent aux structures plus larges qui nous renseignent sur le « contexte » de l'image. Il est par conséquent naturel d'analyser d'abord les détails d'une image à une résolution grossière puis d'augmenter graduellement la résolution, ce qui permet une représentation de l'image suivant des résolutions successives.

III.4.1 Définition de L'analyse en Multi-résolution

On cherche à écrire une fonction $f(x)$ de l'espace des fonctions continues d'une variable réelle et de carré intégrable $L^2(\mathbb{R})$. Chacune d'elle étant la fonction $f(x)$ lissée avec des fonctions de plus en plus concentrées. Ces approximations n'ont pas la même résolution.

L'analyse en multi-résolution est donc une suite croissante de sous-espaces linéaires $V_j (j \in \mathbb{Z})$ de $L^2(\mathbb{R})$ ayant les propriétés suivantes :

- Emboîtement des sous-espaces :

$$V_j \subset V_{j+1} \text{ Si } f(x) \in V_j \text{ alors } f(x) \in V_{j+1}$$

- Densité de l'espace engendré :

$\cup V_j = L^2(\mathbb{R})$, autrement dit, si $f(x) \in L^2(\mathbb{R})$, sa projection $\bar{f}_j(x)$ dans V_j tend vers $f(x)$ lorsque $j \rightarrow -\infty$.

- Propriété d'invariance par translation :

$$\text{Si } f_j(x) \in V_j \text{ alors } \forall k \in \mathbb{Z}, f_j(x - k) \in V_j.$$

- Propriété d'invariance par dilatation :

$$\text{Si } f_j(x) \in V_j \text{ alors } f_j(2x) \in V_{j+1}.$$

Le choix du facteur 2 correspond à celui de l'analyse dyadique. Celle-ci est la plus simple à mettre en œuvre. Il existe cependant d'autres analyses, où le facteur est de $\sqrt{2}$.

- Existence de base

Il existe une fonction $\Phi(x)$ telle que l'ensemble des fonctions $\Phi(x - k)$ forme une base de V_0 .

- Discrétisation

Il existe entre V_0 et $l^2(\mathbb{Z})$ un isomorphisme I . Autrement dit, une fonction $f(x)$ approximée dans V_0 est une fonction $\bar{f}_0(x)$ que l'on peut caractériser par un ensemble de termes $C^{(0)}(k)$ formant un vecteur $l^2(\mathbb{Z})$.

Si l'ensemble des fonctions $\Phi(x - k)$ est une base de V_0 , alors l'ensemble des fonctions $\sqrt{2^j} \Phi(2^j x - k)$ est une base de V_j . L'échelle associée à la résolution j est $a_j = \frac{1}{2^j}$.

On pose :

$$\Phi_j(x) = 2^j \Phi(2^j x)$$

La base s'écrit alors

$$(\sqrt{2^{-j}} \Phi_j(x - 2^j k))$$

Ou en fonction de a_j

$$(\sqrt{a_j} \Phi_j(x - a_j k))$$

La fonction Φ est appelée fonction d'échelle, ou base d'interpolation. La fonction $\Phi_j(x)$ n'est pas de norme unité, son intégrale vaut 1.

III.5 Algorithme de S.MALLAT par l'approche de convolution

L'algorithme de S.Mallat est très utilisé pour la décomposition-reconstruction sur une base orthonormée d'ondelettes. Il est appliqué sur les ondelettes issues d'une analyse multi-résolution qui a comme but de calculer les coefficients de détail D_j^k ou coefficients d'ondelettes, à partir des différentes approximations.

III.5.1 Algorithme unidimensionnel

Soit (V_j) une analyse multi-résolution de $L^2(\mathbb{R})$ et Φ la fonction d'échelle associée et Ψ est l'ondelette analysante à Φ . On a : $V_j = V_{j-1} \oplus W_{j-1}$

Soit $f_j \in V_j$, on se propose de déterminer f_{j-1} projection de f_j sur W_{j-1} et les coefficients d'ondelettes correspondants sur le complémentaire orthogonal W_j .

III.5.1.1 Décomposition

Le signal original $f(n)$ est passé à travers un filtre passe-haut $g[n]$ et à travers le filtre passe-bas $h[n]$. Après le filtrage, la moitié des échantillons seront éliminés. Cela construit un seul niveau de décomposition et qui peut être donné par la formule suivante :

$$y_{haut}[k] = \sum_n f[n] \cdot g[2k - n]$$

(III.12)

$$y_{bas}[k] = \sum_n f[n].h[2k - n]$$

(III.13)

$y_{haut}[k]$ et $y_{bas}[k]$ sont respectivement les résultats du filtre passe-haut et filtre passe-bas après décimation par 2. Cette procédure, qui est aussi connue sous le nom du codage *sous-bande*, peut être répétée pour plusieurs décompositions supplémentaires de la sortie passe-bas qui contient la majeure partie du signal utile, afin de concentrer plus l'énergie, car la décomposition des hautes fréquences n'apporte en général que peu de décorrélation supplémentaire. Cette décomposition successive des basses fréquences est connue sous le nom de Décomposition Dyadique.

La Figure 17 illustre ce qui est dit ci-dessus où $f[n]$ est le signal original à décomposer, $h[n]$ et $g[n]$ sont respectivement le filtre passe-bas et passe-haut.

Les filtres h et g sont des filtres discrets indépendants de j associés à l'analyse multi-résolution $(V)_j$.

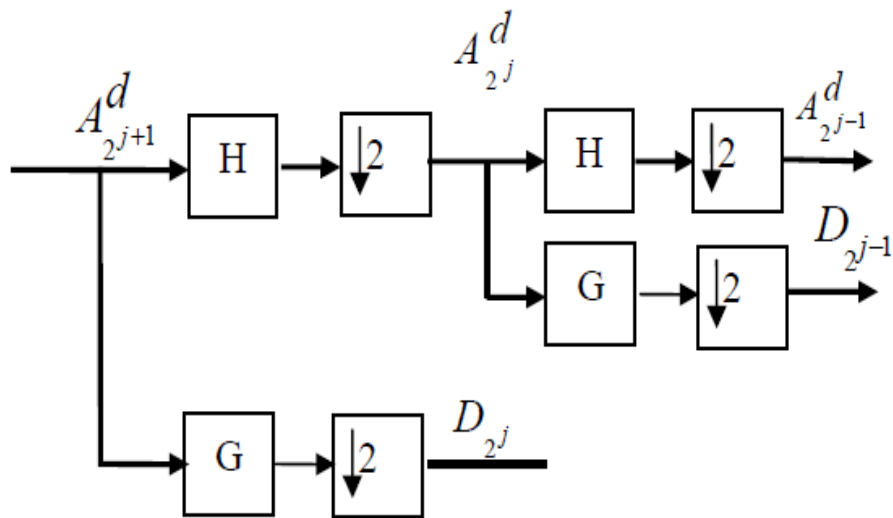


Figure 20 : Schéma de Décomposition unidimensionnelle de l'algorithme de S.Mallat

Les coefficients $A_{2^j}^d$ et D_{2^j} sont donnés par les formules suivantes :

$$A_{2^j}^d = \sum_{n \in \mathbb{Z}} h(n - 2k) A_{2^{j+1}}^d f(n)$$

(III .14)

Avec :

$$h(n) = \frac{1}{\sqrt{2}} \int_{+\infty}^{-\infty} \Phi\left(\frac{x}{2}\right) \Phi(x - n) dx$$

(III .15)

De même :

$$D_{2^j} f(k) = \sum_{n \in \mathbb{Z}} g(n - 2k) A_{2^{j+1}}^d$$

(III .16)

Avec :

$$g(n) = \frac{1}{\sqrt{2}} \int_{+\infty}^{-\infty} \Psi\left(\frac{x}{2}\right) \Phi(x - n) dx$$

(III .17)

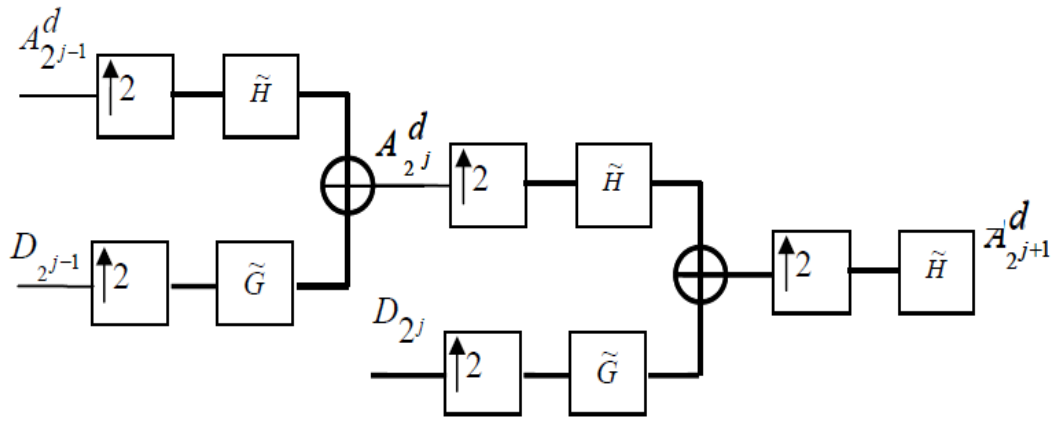
III.5.1.2 Reconstruction

La reconstruction dans ce cas est très simple, la procédure ci-dessus est suivie dans l'ordre inverse pour la reconstruction. Le signal de chaque niveau est interpolé par 2. Ce signal passe à travers les filtres de synthèse $\check{g}[n]$ et $\check{h}[n]$ (respectivement passe-haut et passe-bas), l'expression de la reconstruction devient (pour chaque étape) :

$$A_{2^{j+1}}^d f(n) = \sum_{-\infty}^{+\infty} (D_{2^j} f(k) \check{g}[2k - n]) + (A_{2^j}^d f(k) \check{h}[2k - n])$$

(III .18)

La figure 18 illustre l'algorithme de reconstruction unidimensionnel :



Figure

21 : Schéma de la reconstruction unidimensionnelle de l'algorithme de S.Mallat.

III.5.2 Algorithme bidimensionnel

Cette section est introduite pour aboutir à l'algorithme pyramidal de Mallat qui est utilisé dans les applications de traitement d'images.

L'idée de la DWT est de séparer les basses et les hautes fréquences d'une image. Les premières correspondent à une version grossière de l'image originale dans laquelle les valeurs de pixels ont été moyennées et où aucune variation brusque n'est observée d'un pixel à l'autre. Les hautes fréquences quant à elles contiennent toutes l'information sur les détails de l'image. On comprend aisément que l'information pertinente est contenue dans la version basses fréquences. On dit que l'énergie de l'image est concentrée dans les basses fréquences. Les différentes étapes de l'algorithme de Mallat permettront d'appliquer ce concept.

III.5.2.1 Décomposition

En utilisant l'algorithme de décomposition de Mallat en 2D, une valeur sur deux de l'image originale est supprimée selon les lignes et selon les colonnes à chaque passage de l'ondelette. L'algorithme de décomposition s'écrit :

$$A_{2^j}^d = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} h(2n - k)h(2m - l)A_{2^{j+1}}^d f(k, l)$$

(III .19)

$$D_{2^j}^1 = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} h(2n-k)g(2m-l)A_{2^{j+1}}^d f(k,l)$$

(III .20)

$$A_{2^j}^2 = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} g(2n-k)h(2m-l)A_{2^{j+1}}^d f(k,l)$$

(III .21)

$$A_{2^j}^3 = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} g(2n-k)g(2m-l)A_{2^{j+1}}^d f(k,l)$$

(III .22)

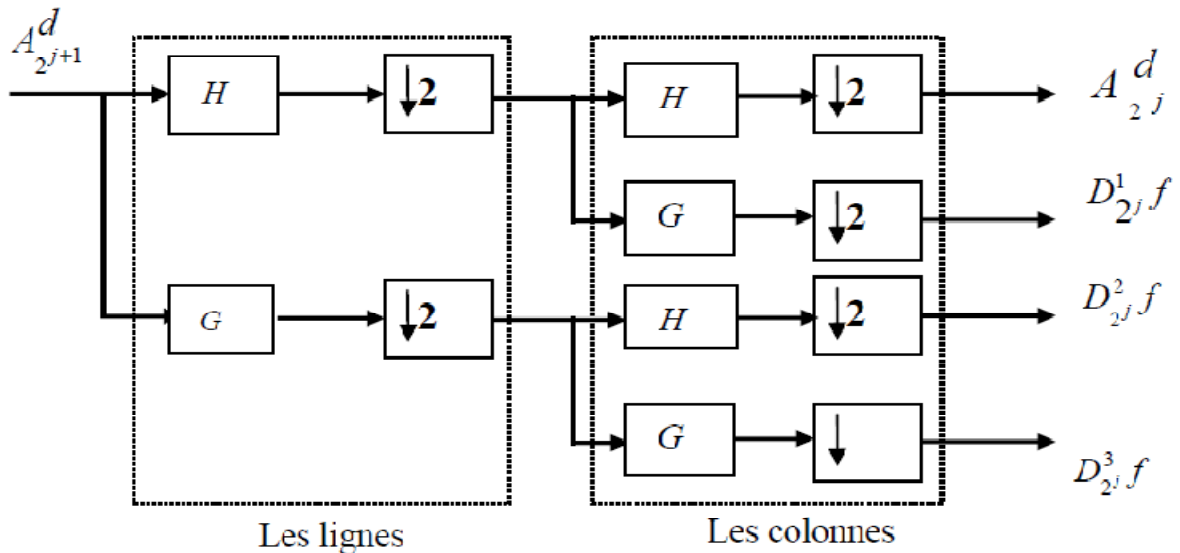



Figure 22 : Analyse d'un signal bidimensionnel par l'algorithme de S. Mallat



III.5.2.2 Reconstruction

L'algorithme de reconstruction s'écrit à l'étape j de la reconstruction comme suit :

$$A_{2^{j+1}}^d = IA_{2^j}^d(n,m) + ID_{2^j}^1(n,m) + ID_{2^j}^2(n,m) + ID_{2^j}^D$$

(III .23)

Avec les formules d'interpolation :

$$IA_{2^j}^d f(n, m) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} \tilde{h}(n - 2k) \tilde{h}(m - 2l) A_{2^j}^d f(k, l) \quad (\text{III .24})$$

$$ID_{2^j}^1 f(n, m) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} \tilde{h}(n - 2k) \tilde{g}(m - 2l) D_{2^j}^1 f(k, l) \quad (\text{III .25})$$

$$ID_{2^j}^2 f(n, m) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} \tilde{g}(n - 2k) \tilde{h}(m - 2l) D_{2^j}^2 f(k, l) \quad (\text{III .26})$$

$$ID_{2^j}^3 f(n, m) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} \tilde{g}(n - 2k) \tilde{g}(m - 2l) D_{2^j}^3 f(k, l) \quad (\text{III .27})$$

Le schéma de la reconstruction est illustré par la Figure

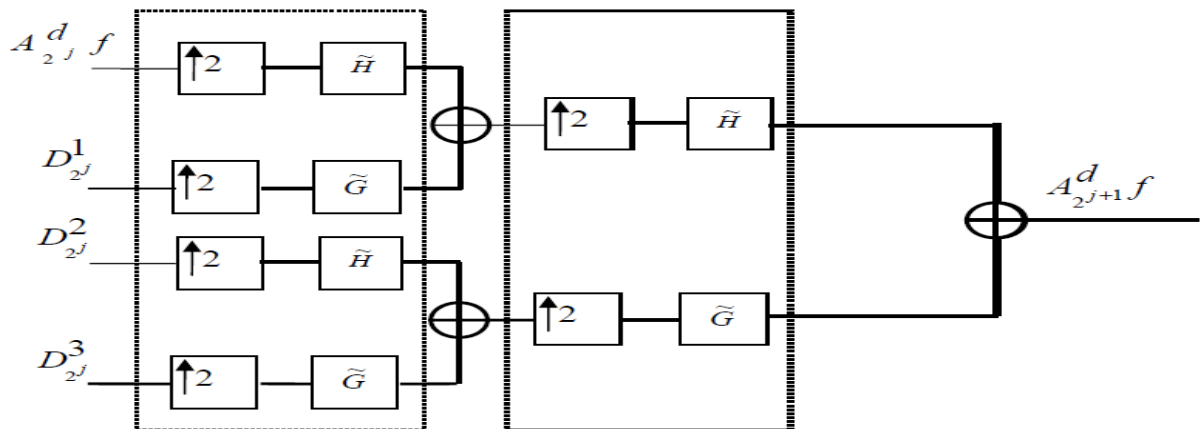


Figure 23: Schéma de reconstruction de Mallat

H : filtre passe bas ; G : filtre passe haut ; $\downarrow 2$: sur-échantillonnage.

Exemple : exemple illustrant la décomposition en ondelette en utilisant l'ondelette de « Haar »




Figure 24 : schéma de décomposition d'une image à 2D

Discussion

Dans ce chapitre nous avons abordé les étapes nécessaires à la mise en œuvre de la théorie des ondelettes et le principe de la multi-résolution, sans évoquer les démonstrations ardues des mathématiques. Dans le chapitre suivant nous présenterons la théorie des champs de Markov.

Chapitre IV

Segmentation par approche markovienne multi-résolution

Préambule

Les champs de Markov sont utilisés depuis maintenant une dizaine d'années en traitement d'images et font désormais partie des techniques de base de cette discipline. Nés à l'origine dans le cadre de la physique statistique pour étudier les phénomènes de transition de phase ils sont rapidement appliqués aux réseaux bidimensionnels que constituent les images. Les premiers modèles sont restreints par des contraintes de causalité, et donc limités jusqu' à l'article fondateur de Geman et Geman en 84 [24], qui ouvre réellement leur utilisation en traitement d'images. Cette utilisation ira croissante avec les années et donnera lieu à de nombreuses recherches sur les problèmes que suscitent leur utilisation (calcul des paramètres des modèles, techniques de simulation et de recherche de solutions rapides, etc.). A côté de ces travaux toujours d'actualité, se sont ouvertes de nouvelles recherches dédiées à des tâches de plus haut niveau et visant à l'interprétation des images.

IV.1 Modélisation d'une image

Une image I est représentée par un ensemble S de sites correspondant aux pixels. A chaque site est associé un descripteur prenant ses valeurs dans l'ensemble des descripteurs E. Ce descripteur traduit le potentiel ou l'intensité du pixel (par exemple le niveau de gris).

IV.2 Notion de la théorie des graphes

La définition d'un champ de Markov ou d'un champ de Gibbs nécessite l'introduction de quelques notions de la théorie des graphes. Nous rappelons, brièvement quelques notions fondamentales en nous restreignant à la définition de celle-ci dans le cas de l'application de la modélisation markovienne à des problèmes d'analyse d'image.

IV.2.1 Système de voisinage

Les pixels de l'image sont reliés par un système de voisinage défini comme suit :

$$\forall s \in S, s \notin \Gamma_s(S)$$

$$\forall \{s, t\} \in S, s \in \Gamma_t(S) \Leftrightarrow t \in \Gamma_s(S) \quad (IV.1)$$

Nous pouvons aussi trouver un autre système de voisinage appelé système de voisinage d'ordre r (r-order Neighborhood system) défini comme suit :

$$\Gamma_s^r(S) = \{t \in S \mid \text{distance}(s, t)^2 \leq r^2, s \neq t\} \quad (IV.2)$$

Le premier et le second ordre sont les plus utilisés.

Dans les images à deux dimensions, le pixel peut avoir soit 4-voisins, on parle alors de système 4-voisinage, ou bien il peut avoir 8-voisins, dans ce cas on parle de système 8-voisinage.




Figure 25 : Systèmes de voisinage 2D

IV.2.2 Notion de clique

A partir d'un système de voisinage, un système de cliques peut être déduit : une clique est soit un singleton de S, soit un sous ensemble de sites tous voisins les uns des autres. Nous noterons C l'ensemble de cliques et C_k l'ensemble de cliques de cardinal k. La figure suivante illustre les cliques associées aux systèmes de voisinage 2D.




Figure 26 : Les cliques associées aux systèmes de voisinage 2D.

A chaque clique $c \in C$ est associé un potentiel U_c , sa valeur dépend des descripteurs des pixels constituant la clique. L'énergie globale de l'image est alors définie comme la somme des potentiels de toutes les cliques :

$$U = \sum_{c \in C} U_c \quad (\text{IV.3})$$

L'énergie locale en un site S est définie comme la somme des potentiels de toutes les cliques auxquelles il appartient :

$$U_{S=} = \sum_{c \in C/S \in c} U_c \quad (\text{IV.4})$$

IV.3 Champs de Markov et distributions de Gibbs

IV.3.1 Champs de Markov

La définition d'un champ de Markov X est la suivante :

$$\forall w \in E, P_X(w) > 0$$

$$\forall s \in S, \forall w \in E,$$

$$P_X[X_s = w_s / X_t = w_t, t \in S, t \neq s] = P_X[X_s = w_s / X_t = w_t, t \in \Gamma_s(S)] \quad (\text{IV.5})$$

On dit alors que X est un champ aléatoire de Markov (MRF) sur S relativement au système de voisinage $\Gamma(S)$ ou simplement sur le graphe $[S, \Gamma(S)]$. Cela veut dire que la probabilité d'observer un descripteur x_s en S ne dépend pas de toute l'image mais uniquement des descripteurs des sites voisins de S , appelé aussi propriété de "markoviennité".

IV.3.2 Champs de Gibbs

Un champ aléatoire $X = \{X_s, s \in S\}$ est un champ de Gibbs sur S relativement au système de voisinage $\Gamma(S)$ si et seulement si P_x est une distribution de Gibbs donnée par :

$$\forall w \in E, P_X(w) = \frac{1}{Z} \exp \left\{ -\frac{U(w)}{T} \right\}$$

(IV.6)

Avec

$$Z = \sum_{x \in E} e^{-\frac{U(w)}{T}}$$

(IV.7)

On dit aussi que X est un champ aléatoire de Gibbs (GRF) sur le graphe $[S, \Gamma(S)]$.

Z est une constante de normalisation appelée fonction de partition ; la fonction :

$$U(w) = \sum_{c \in C} V_c(w) \quad (\text{IV.8})$$

est définie sur E , c'est la fonction d'énergie du champ de Gibbs X et $\{V_c, c \in C\}$ est une famille de potentiels sur les cliques du graphe $[S, \Gamma(S)]$.

IV.3.3 Théorème de Hammersley_Clifford

Un champ de Markov est caractérisé par sa propriété local ("markoviennité") alors qu'un champ de Gibbs par sa propriété globale (distribution de Gibbs). Le théorème de Hammersley_Clifford établit l'équivalence entre champs de Markov et champs de Gibbs vérifiant la propriété de positivité.

Un champ aléatoire sur l'ensemble fini de sites S est un champ de Markov sur le graphe $G = [S, \Gamma(S)]$ vérifiant la propriété de positivité si et seulement si c'est un champ de Gibbs sur G .

IV.4 Modélisation markovienne

Cette partie traite spécifiquement du problème de la segmentation markovienne d'image. Cette segmentation utilise l'estimateur du maximum à posteriori (MAP) qui est mis en œuvre par un algorithme de relaxation.

La première partie expose le principe de segmentation bayésienne. Elle traite d'une part, la modélisation du champ d'observation utilisant le modèle de distribution de probabilité conditionnelle et d'autre part, la modélisation markovienne du champ des classes utilisant la distribution de probabilité à priori. La deuxième partie sera consacrée à l'étude des algorithmes de minimisations (stochastiques et déterministes), et la justification de notre choix.

IV.4.1 Position du problème de la segmentation d'image

Une image est un réseau de pixels. Chaque pixel peut être repéré par un couple d'indices ligne, colonne (i, j) (avec $1 \leq i \leq m$ et $1 \leq j \leq n$, (m, n) correspondant au nombre de lignes et de colonnes respectivement) ou par un numéro « s » (dans ce cas, le pixel s'appelle site). Pour un réseau donné, une image est caractérisée par les valeurs de niveau de gris. Ces valeurs sont quantifiées par un entier variant dans un intervalle fixé (généralement $[0, 255]$).

Le principe de la segmentation est le suivant :

Soit $X = (X_1, \dots, X_n)$ le champ des classes. pour chaque site $s \in (1, 2, \dots, N)$ (ensemble de pixels), X prend sa valeur dans $\Omega = (w_1, w_2, \dots, w_t)$ ensemble des classes, k étant le nombre de classes. L'image des classes n'est pas directement accessible et le champ $F = (F_1, F_2, \dots, F_n)$ s'appelle champs des observations. Il représente une image bruitée. Il

s'agit alors, à partir d'une réalisation "f" d'un champ aléatoire F, d'attribuer une estimation "w".

La segmentation utilise le critère du maximum de probabilité à posteriori (MAP) $P(X = w / y = f)$. Cette approche est dite bayésienne. Elle est motivée par le désir d'obtenir une segmentation qui tienne compte de l'information à priori dans les données de l'image. Le paragraphe suivant décrit la stratégie bayésienne et le principe de maximum de probabilité à posteriori.

IV.4.2 Estimation bayésienne

La théorie statistique bayésienne est d'une importance fondamentale dans tout problème d'estimation ou de décision. Elle est particulièrement bien adaptée aux problèmes d'estimation pour lesquels l'à priori P_x , traduisant les propriétés pertinentes de la classe des solutions recherchées, et la fonction de vraisemblance $P_{F/X}$, modélisant le processus de dégradation conduisant aux observations, sont connues.

Si on note la solution recherchée (exacte) par $w^r \in E$, alors son estimée $\varpi \in E$ optimale au sens bayésien est celle qui minimise le risque de Bayes, définie comme étant l'espérance conditionnelle aux observations d'une fonction de coût. En d'autres termes,

$$\varpi = \arg \min_x \int C(w^r, w) P_{X/Y}(w^r / f) dw^r$$

(IV.9)

L'estimation de la solution recherchée nécessite outre la spécification de la fonction de coût, la connaissance de la distribution de probabilité à posteriori donnée par :

$$P_{X/Y}(w/f) = \frac{P_{Y/X}(f/w) P_X(w)}{P_Y(f)} \propto P_{Y/X}(f/w) P_X(w) \quad (IV.10)$$

La fonction de coût mesurant l'écart entre la solution recherchée w^r (vraie) et son estimée ϖ , est généralement laissée à l'appréciation de l'utilisateur. Cependant une fonction, souvent utilisée, définit l'estimateur le plus répondu dans la littérature que nous détaillerons ci-dessous : l'estimateur au sens du maximum à posteriori (MAP).

IV.4.2.1 Estimateur au sens du maximum à posteriori(MAP)

L'estimation au sens du MAP maximise la densité de probabilité *à posteriori*, équivalent à la minimisation d'une fonction d'énergie reposant sur (i) la vraisemblance de la solution par rapport aux observations. Donc nécessitant la connaissance ou la modélisation de tous les phénomènes de dégradation de l'objet original durant le processus d'observation, (ii) la spécification d'un *à priori* sur la solution recherchée.

D'après (IV.9) et (IV.10)

$$_{MAP} = \arg \max_x P_{X/Y}(X = w/F = f) \quad (IV.11)$$

$P(X = w/F = f)$: La probabilité conditionnelle de la classe "w" sachant l'observation "f". En utilisant la règle de bays, la probabilité *a posteriori* est exprimée comme :

$$P(X = w/F = f) = \frac{P(F=f/X=w)P_x(X=w)}{P_Y(F=f)} \quad (VI.12)$$

$P(F = f/X = w)$: représente la distribution de la probabilité conditionnelle de l'observation "f" sachant la classe "w"

$P(X = w)$: est la distribution de la probabilité de la classe "w" (probabilité a priori) qui peut être modélisée en posant une contrainte de connectivité spatiale sur la classification.

$P(F = f)$: est la distribution de probabilité que l'observation "f" survienne.

La recherche du minimum global est souvent faite par des algorithmes coûteux en termes de temps de calcul tels que les algorithmes stochastiques de type recuit.

Néanmoins, des solutions approchées peuvent être obtenues par des algorithmes déterministes comme l'ICM [25] Dans le cas des problèmes de segmentation, la configuration MAP-ICM est la plus répandue.

IV.4.3 Modélisation du champ des observations

La densité de probabilité conditionnelle $P(f/w)$ peut être modélisée par une loi gaussienne.

Avec

$$P(w/F) = \frac{1}{P(F)} P(F/w)P(w) \quad (IV.13)$$

La probabilité $P(f_s/w_s)$ (avec f_s désigne la valeur observée du site "s" peut être modélisée sous la forme suivante [26] :

$$P(f_s/w_s) = \frac{1}{\sqrt{2\pi\sigma_{w_s}^2}} \exp\left(-\frac{(f_s - \mu_{w_s})^2}{2\sigma_{w_s}^2}\right)$$

(IV.14)

Où $\sigma_{w_s}^2$ est la variance de la classe;

μ_{w_s} est la moyenne de la classe.

La détermination de cette probabilité est liée à l'ensemble des moyennes et des variances des classes. Cet ensemble forme le vecteur des paramètres à estimer.

En supposant que $P(f_s/w_s)$ soit strictement supérieure à zéro, on pose :

$$E_1(f/w) = -\ln P(f_s/w_s)$$

(IV.15)

Elle sera considérée comme une composante de l'énergie globale qui sera utilisée pour déterminer la classe la plus probable.

IV.4.4 Modélisation markovienne du champ des classes

Généralement, dans les méthodes de segmentation conventionnelles telles que la méthode du maximum de vraisemblance, la probabilité *a priori* est supposée identique pour toutes les classes. Cela est incorrect en général, en ce qui concerne les objets d'une scène naturelle. De plus, le résultat final de la segmentation peut inclure des régions isolées à cause de la présence du bruit. Afin d'éviter ces problèmes, l'utilisation de l'information du voisinage permet de jouer un grand rôle dans la détermination des probabilités *a priori*. Il s'agit alors, d'assimiler le champ des classes à un champ markovien.

IV.5 Hypothèses markoviennes

On suppose que chaque pixel est étroitement lié à ses voisins. Le champ des classes X est considéré comme un champ aléatoire de Markov par rapport au système de voisinage si la loi de probabilité conditionnelle de w_{s_s} sachant w_T , (avec $T \neq s$ et "T" est l'ensemble des pixels dans l'image), est égale à la loi de probabilité conditionnelle de w_{s_s} sachant w_{t_s} ($t \in \Gamma_{s_s}$ et "t" est l'ensemble des sites formant le voisinage). (voir équation (VI.5)).

Cela signifie que la connaissance d'un voisinage local Γ_{s_s} , du pixel "s" est suffisante pour calculer la probabilité en chaque pixel "s".

le Champ de Markov permet de préciser la dépendance aléatoire entre les pixels voisins : qu'on observe l'image entière (sauf le pixel "s") ou le voisinage Γ_{s_s} (sauf le pixel "s"), on obtient la même densité de probabilité conditionnelle [27]. La supposition que toutes les configurations du champ X ont une probabilité non nulle de se produire permet de considérer que le champ X des classes a une distribution de Gibbs relative à (S, Γ) . La distribution de Gibbs permet d'imposer la contrainte de connectivité sur le champ de classe. Cette distribution est une mesure de probabilité $P(w)$ sur l'ensemble des classes, elle est donnée par l'équation (IV.6).

Le théorème d'Hammersley-Clifford [28], permet alors d'exprimer la fonction d'énergie E_2 en fonction des valeurs de "w" sur "les cliques" du voisinage (Γ_{s_s}) utilisé [24]. La fonction d'énergie $E_2(w)$ est obtenue sous la forme d'une somme de potentiels locaux $V_c(w)$ sur les cliques c de C de la façon suivante :

$$E_2(w) = \sum_{c \in C} V_c(w) \quad (\text{IV.16})$$

Où V_c est la fonction de potentiel associé à chaque clique c . C est l'ensemble de cliques correspondant au voisinage choisi. La fonction de potentiel permet de caractériser la différence ou la ressemblance entre les pixels de chaque clique.

En utilisant un système de voisinage des quatre ou huit plus proche voisins et en considérant seulement les cliques à deux pixels, la fonction de potentiel V_c est choisie comme suit :

$V_c = B$ si les deux pixels de la clique ont des valeurs différentes.

$V_c = -B$ si les deux pixels de la clique ont la même valeur.

Où B est un paramètre positif à estimer. Le rôle de ce paramètre est de favoriser l'homogénéité spatiale entre pixels voisins.

Cette fonction de potentiel impose une contrainte de connectivité spatiale sur la segmentation. L'affectation du potentiel permet de donner une probabilité faible pour les paires de pixels ayant des étiquettes distinctes.

IV.5.1 Fonction d'énergie globale

Comme nous l'avons vu dans l'équation (IV.6) et (IV.14) $P(F/X)$ et $P(X)$ sont des fonctions exponentielles. Si nous supposons que :

$$E_1(f/w) = -\ln P(f_s/w_s) \quad (IV.17)$$

$$E_2(w) = -\ln P(w_s) \quad (IV.18)$$

L'estimateur du maximum à *priori* de l'équation IV.10 devient :

$$\hat{w} = \underset{w}{\operatorname{arg\,max}} (\exp - (E_1(f/w) + E_2(w))) \quad (IV.19)$$

Lorsque, seules les fonctions d'énergie sont considérées, nous avons :

$$\hat{w} = \underset{w \in \Omega}{\operatorname{arg\,max}} (\exp - (E_1(f/w) + E_2(w))) \quad (IV.20)$$

Donc, la configuration de la classe la plus probable est celle qui présente une énergie globale minimale E_G , avec :

$$E_G(w, f) = E_1(w/f) + E_2(w) \quad (IV.21)$$

Nous constatons que la fonction globale d'énergie a deux composantes : l'une utilise l'intensité des régions obtenue à partir des données observées et l'autre impose la connectivité spatiale entre les classes. Par conséquent, l'estimation de la segmentation ne dépend pas uniquement de l'intensité des images mais aussi des propriétés spatiales imposées par le modèle du champ aléatoire de Markov.

IV.6 Algorithme de minimisation

L'estimation au sens du MAP associée à une modélisation markovienne nous conduit toujours à un problème de minimisation d'une fonction d'énergie. Ainsi le problème d'estimation devient donc un problème d'optimisation difficile car la fonction d'énergie présente de nombreux minima locaux. De ce fait, il est nécessaire de faire appel à des algorithmes itératifs pour tenter d'approcher un minimum global. On trouve :

- les algorithmes de relaxation stochastique de type recuit [29], les seuls possédant des propriétés de convergence asymptotique (en un temps infini) vers un minimum global et indépendamment de la configuration initiale ;

- les algorithmes déterministes [30], convergeant vers un minimum local qui dépend de la configuration initiale.

La littérature dans ce domaine est très vaste [29],[31],[24],[25], [30], (pour ne citer que les travaux les plus important) et on trouve souvent plusieurs versions d'une même technique d'optimisation.

IV.7 Model markovien multi résolution

C'est le modèle hiérarchique le plus simple. Le problème à résoudre à un niveau i de la pyramide est celui de la minimisation sur E^i d'une certaine fonction d'énergie $U_{\theta^i}^i(X^i, Y^i)$ à définir, connaissant Y^i "approximation" de l'observation originale sur la sous grille S^i . La séquence $Y^i, i = 1, \dots, n$ est obtenue par filtrage passe-bas et décimation successive de Y :

$$Y^{i+1} = [(\downarrow 2) \circ H](Y^i) \quad (\text{IV.22})$$

Où H est un filtre linéaire passe-bas associé par exemple à une famille d'ondelettes.

Les fonctions d'énergie à chaque niveau de la pyramide sont définies de façon heuristique par une simple duplication de la fonction d'énergie originale. En d'autres termes, le modèle markovien utilisé reste le même à savoir :

- (i) toutes les grilles S^i sont munies du même système de voisinage similaire à celui de S ;
- (ii) les potentiels des cliques engendrées V_c^i , ont la même expression que les potentiels V_c ;
- (iii) le terme d'attache aux données est défini de la même façon pour tous les niveaux. Ainsi, la fonction d'énergie à minimiser, définie sur E^i , paramétrée par le vecteur θ^i , est donnée par :

$$U_{\theta^i}^i(X^i, Y^i) = \sum_{s \in S^i} F_s^i(X_s^i, y_s^i) + \sum_{c \in C^i} V_c^i(X^i) \quad (\text{IV.23})$$

$$= \sum_{s \in S^i} F_s(X_s^i, y_s^i) + \sum_{c \in C^i} V_c(X^i) \quad (\text{IV.24})$$

La double structuration pyramidale observations_ étiquettes est illustrée en Figure27. Le problème d'optimisation ainsi défini, nécessite l'estimation de $n + 1$ jeux de paramètres, chose qui est en soi un problème complexe. Dans la plupart des travaux, pour $i > 0$, un réglage heuristique des paramètres est effectué sur la base des paramètres à la résolution 0. La stratégie utilisée pendant le processus d'optimisation est généralement celle du plus grossier vers le plus fin: "coarse to fine". Le passage d'une résolution $i + 1$ à une autre i plus fine nécessite l'utilisation d'un opérateur d'interpolation qui est soit une duplication sur des blocs 2×2 soit une interpolation lorsque la nature des labels le permet.

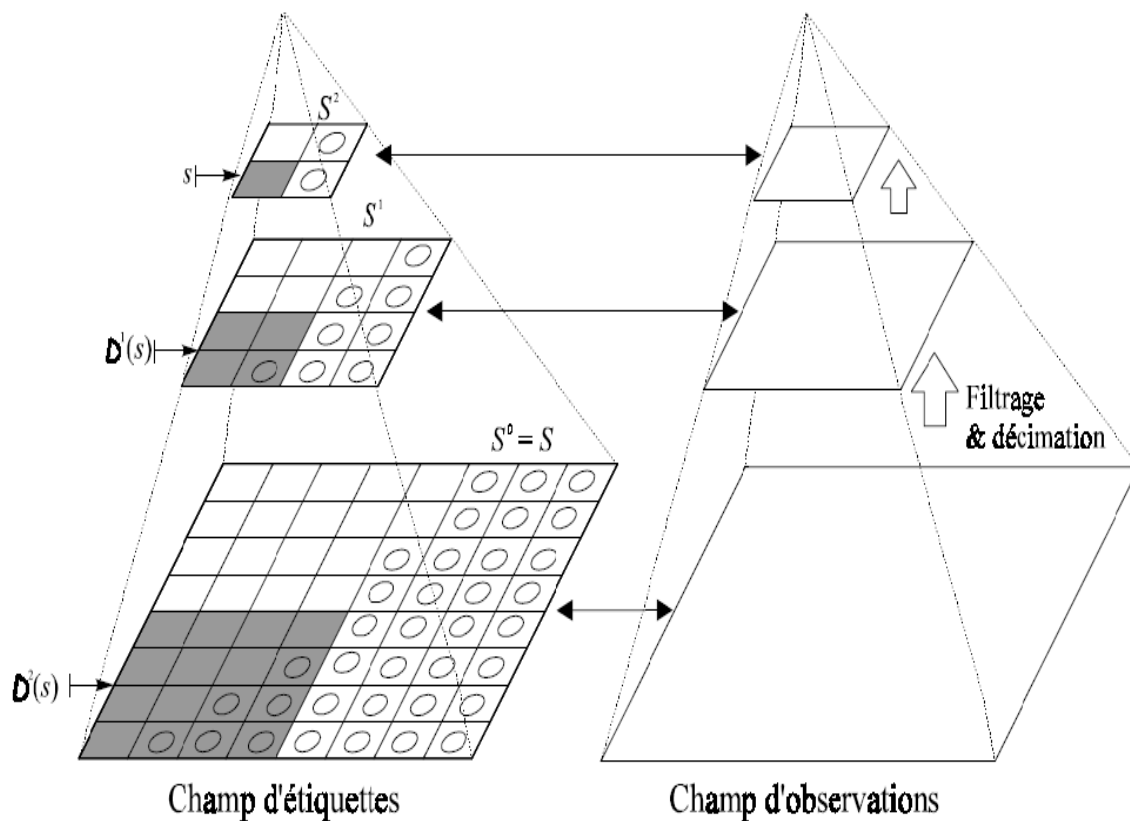


Figure27 : Structuration pyramidale des étiquettes et des observations en vue de
L'utilisation d'un modèle markovien multi résolution.

IV.8 Méthode adoptée

IV.8.1 Présentation de la méthode de segmentation adoptée

La méthode que nous avons élaborée comporte trois phases distinctes qui sont :

1. la phase de décomposition en trois niveaux en utilisant la décomposition en ondelette,
2. la phase d'initialisation qui consiste à faire une classification primaire en appliquant la méthode de K-means
3. la phase de segmentation.

IV.8.2 Décomposition en ondelette

La transformée en ondelettes permet de représenter une image à différents niveaux de résolution, elle fournit au niveau de résolution j une approximation A^{-j} de l'image de départ et trois images de détails D_1^{-j} , D_2^{-j} et D_3^{-j} privilégiant chacune une orientation particulière : Horizontale (indice 1), verticale (indice 2) et diagonale (indice 3). Ces images renferment les informations perdues lors du passage du niveau de résolution précédent ($j-1$) au niveau (j).

IV.8.3 Classification par la méthode des K-means

Après avoir calculé les différents attributs de tout pixel de l'image, on passe à la classification des ces derniers dans différentes classes texturées.

La méthode que nous avons retenue pour effectuer cette tâche est basée sur l'algorithme de K-means qui cherche généralement à partitionner l'espace en K classes isolées les unes des autres.

L'algorithme de K-means vise à minimiser une certaine distance entre chaque pixel et les différents noyaux de chaque classe, c'est-à-dire, il affecte chaque élément à une classe sur la base de mesure de la plus petite distance de similarité. Le point sensible de K-means réside essentiellement dans l'initialisation aléatoire des centres de classes.

En effet, le choix des centres de classes influe beaucoup sur la convergence et la qualité du résultat. L'algorithme des K-means est illustré dans le paragraphe suivant :

Etape 1 : initialisation

1- introduire la taille de l'image (m : nombre de lignes, n : nombre de colonnes).

2- introduire la taille de la fenêtre de voisinage.

3- introduire le nombre de classes (nombre de textures présentes dans l'image N_c).

4- Calculer les attributs de la texture pour chaque pixel.

Remarque : le calcul d'attributs de chaque pixel se fait en prenant en considération tous les pixels appartenant à la fenêtre de voisinage centrée sur ce pixel.

Le vecteur d'attributs est noté par :

$$V_i = (a_{i1}, a_{i2}, \dots, a_{inp})$$

a_{ij} constitue les attributs du pixel P_i avec $j = 1, 2, \dots, np$

np est le nombre d'attributs

Etape 2 : initialisation des centres de classes

Initialiser au hasard N_c centres de gravité $[g_1, g_2, \dots, g_{N_c}]$ qui correspond à N_c classes.

Avec $g_k = [g_{k1}, g_{k2}, \dots, g_{knp}]$

Etape 3 : affectation

1- affectation de chaque pixel P_i à une classe C_K dont le centre est g_k . Un pixel P_i appartient à la classe C_K de centre g_k si seulement si la distance $\text{Dist}(X_i, g_k)$, est minimale pour tout

$K = 1, \dots, N_c$.

2- mettre à jour la position du centre de gravité g_k de la classe C_K

$$g_{kj} = \frac{1}{N_K} \sum_{i \in C_K} a_{ij}$$

(IV.25)

Où N_K est le nombre de pixels de la classe C_K .

3- répéter à chaque fois l'étape 3 pour chaque individu, jusqu'à ce que deux étapes successives ne modifient pas le contenu des classes.

Dans cette étape on aura une image segmentée qui sert d'initialisation pour l'algorithme ICM.

IV.8.4 Phase de segmentation

La segmentation au sens de la maximisation à posteriori (MAP) consiste à déterminer la valeur de la classe la plus probable qui maximise $P(X/F)$ ou de manière équivalente, qui minimise la fonction d'énergie globale $E_G(w, f)$.

L'algorithme ICM (Iterated Conditional Modes) permet de déterminer le minimum global de la fonction d'énergie. Il est basé sur la loi de Gibbs. Cette loi a pour origine la thermodynamique statique et le magnétisme. C'est pour cela qu'une terminologie propre aux physiciens (terme d'énergie) se trouve souvent dans la description de l'algorithme.

Les étapes de cet algorithme sont décrites ci-dessous :

- i) Initialisation de l'algorithme ICM : il s'agit de fournir à l'algorithme ICM une image segmentée et d'estimer les paramètres a de la classification initiale.

(Les paramètres a sont la variance et la moyenne)

Moyenne

$$m = \frac{1}{MN} \sum_{mn=1}^{MN} |x_{mn}| \quad (\text{IV.26})$$

(IV.27)

Variance

$$\sigma_x^2 = \frac{1}{MN} \sum_{mn=1}^{MN} (x_i - \mu_x)^2$$

- ii) A partir d'une configuration initiale, les étapes suivantes sont réalisées pour chaque pixel :
 - a) Pour chaque classe :
 - Calcul de l'énergie E_1^i (voir IV.17)
 - Calcul de l'énergie E_2^i (voir IV.18)
 - Calcul de l'énergie E_3^i (voir IV.21)
 - b) Recherche de la classe d'énergie minimale.
- iii) On affecte l'étiquette de la classe, trouvée dans l'étape b), au site courant.
- iv) S'il y a eu des changements sur l'image classifiée et si le nombre de changements est supérieur au seuil que nous avons défini, on retourne à l'étape (ii). Sinon, l'algorithme ICM s'arrête.

Remarque :

- Le critère d'arrêt peut être, soit un nombre d'itérations fixé par l'utilisateur, soit un seuil à ne pas dépasser sur le nombre de pixels ayant changé de classe à la dernière itération.
- Dans notre cas, nous avons fixé le nombre d'itérations comme un critère d'arrêt.
- On applique ces algorithmes aux différents niveaux de décomposition.

L'organigramme ci-après représente les différentes étapes de la méthode élaborée.

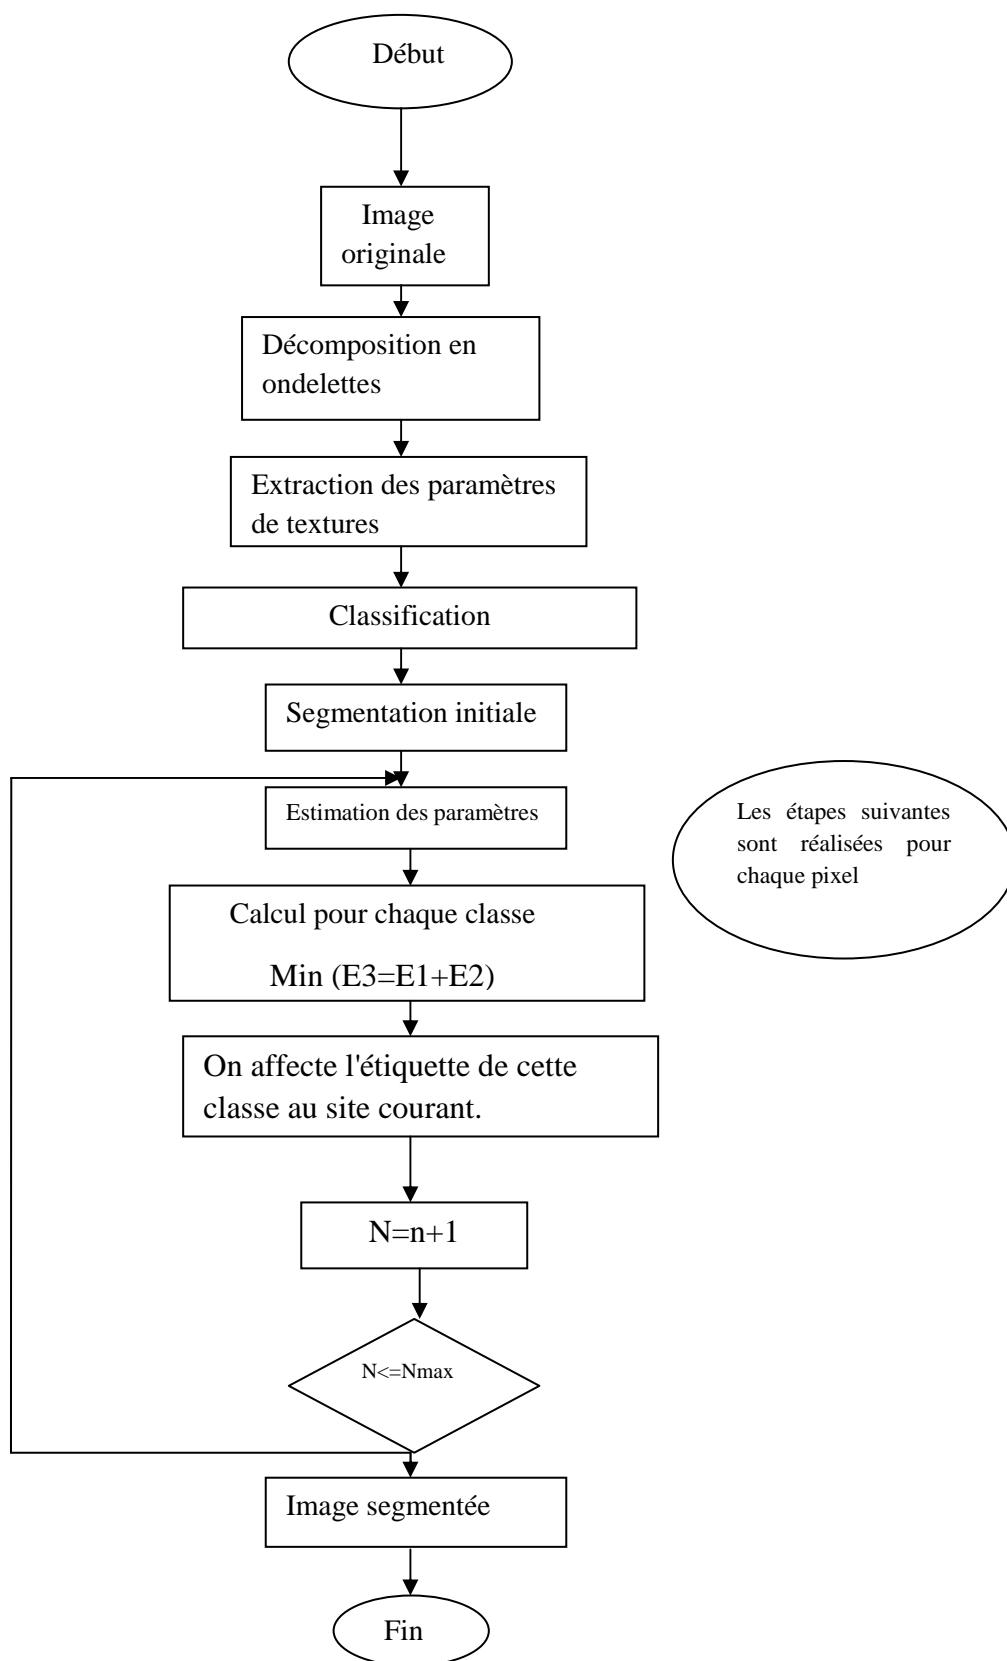


Figure 28 L'organigramme représentant les différentes étapes de la méthode élaborée

Discussion

Dans ce chapitre, nous avons essayé de développer la notion des champs de Markov et de présenté la méthode de segmentation multi résolution basée essentiellement sur les champs de Markov et l'estimation bayésienne. Très sommairement, notre méthode consiste à décomposer l'image en plusieurs résolutions, ensuite on calcule les différents paramètres de texture, ce qui nous permet d'avoir une image pré segmentée en appliquant l'algorithme de K-means.

Cette image sert d'initialisation pour l'algorithme ICM qui s'avère important puisqu'il se base sur une méthode déterministe qui a la propriété de converger rapidement. Il est déterministe dans le sens où, l'examen d'un site «s » permet systématiquement d'affecter au site « s » la classe pour laquelle l'énergie est minimale. L'algorithme ICM est un algorithme itératif et permet de minimiser la fonction d'énergie à chaque pixel, connaissant la valeur observée du pixel et la classe courante de tous les autres pixels à l'intérieur de la fenêtre du voisinage. L'ensemble des pixels de la fenêtre du voisinage est utilisé dans le calcul de la probabilité *à priori* basée sur la loi de Gibbs.

Les différents tests et résultats seront exposés, commentés et interprétés dans le prochain chapitre.

Chapitre V

Tests et résultats

Préambule

Dans ce chapitre, nous exposerons les résultats des tests que nous avons effectués sur quelques images tirées de l'album de Brodatz et des images Météosat. Dans notre application l'ondelette utilisée est celle de Haar, ce choix revient au bon résultat qu'on a obtenu après plusieurs tests, par rapport aux autres types d'ondelettes (Daubechie et biorthogonale). L'algorithme de segmentation a été implémenté en langage de programmation MATLAB.

V. Présentation des données

V.1 Images de Brodatz

Afin d'évaluer les performances de la méthode mise au point, nous avons sélectionné un ensemble d'images tests tirées de l'album de Brodatz, dont on a des connaissances a priori (les textures sont parfaitement identifiées et le nombre de classes est connu). Par conséquent, les résultats d'analyse et de la segmentation seront jugés par rapport à l'image d'origine.

La taille de ces images est de 256×256 pixels avec 256 niveaux de gris. Elles sont composées de régions diverses fortement texturées. L'image test1 est constituée de trois régions texturées, l'image test2 est constituée de quatre régions texturées, et l'image test3 présente cinq régions texturées.




Figure 29.a: Test1




figure 29.b: Test2




Figure 29.c : Test3

V.1.2 Images Météosat

Dans cette section, nous allons tester notre méthode sur des images Météosat prises par le météosat4 dans les bandes spectrales visibles et infrarouge avec une résolution de 5*5 km. Dans ce genre d'images, on a aucun critère de comparaison du fait qu'on a aucune connaissance a priori sur ces images. La taille de ces dernières est de 512*512 pixels. Pour les deux types d'images, les valeurs possibles des niveaux de gris vont de 0 à 255.

Les choix de ce type d'images n'est pas fortuit, car en apparence, ces images montrent des régions fortement texturées. L'objectif de la segmentation de ce type d'images, est la mise en évidence de différentes zones nuageuses présentes dans celles-ci, Pour une bonne interprétation des phénomènes météorologiques qu'elles peuvent contenir.




Figure 30.a : Image 1 (visible)




figure 30.b : Image2(infra-R)

V.2 Présentation du logiciel utilisé

Le programme élaboré a été réalisé sous MATLAB sous l'environnement Windows. On rappelle que MATLAB est l'abréviation de « MATrix LABoratory », c'est un logiciel de calcul scientifique dédié plus particulièrement aux applications numériques. A l'origine, il a été conçu pour manipuler des données matricielles, ce qui on fait de ce logiciel un outil majeur de l'analyse de données, du traitement du signal, du traitement d'images, de simulation numérique etc. il dispose d'une syntaxe spécifique mais elle est simple et intuitive.

MATLAB propose deux types de fonctionnement :

- Un fonctionnement en ligne de commande où MATLAB exécute les instructions au fur et à mesure qu'elles sont données par l'utilisateur (MATLAB commande).
- Un fonctionnement via des scripts, dans ce cas, MATLAB exécute ligne par ligne un fichier texte que l'on désigne par programme (MATLAB editor).

MATLAB propose également une aide très complète illustrée d'exemple, étant donnée le très grand nombre d'instruction utilisables, il est important de bien savoir l'utiliser.

Pour notre méthode, on utilise la version MATLAB 7.10.0.499 (R2010a).

III .3 Application de la méthode

Dans notre application, la décomposition en ondelettes est effectuée jusqu'au niveau trois pour bien voir l'efficacité de l'algorithme markovien dans la discrimination de texture. La segmentation des images texturées exige des fenêtres d'analyse moins larges pour la localisation plus exacte des frontières entre différentes textures, après avoir fait plusieurs tests, les tailles des fenêtres qu'on a choisi sont $5*5$, $7*7$ et $9*9$.

V.3.1 Cas des images tests de Brodatz

a) Le premier niveau de décomposition

➤ Image test1




Image originale





Image segmentée



colormap

Figure 31 : Résultat de la segmentation de l'image test1

➤ **Image test2**




Image originale





Image segmentée



colormap

Figure 32 : Résultat de la segmentation de l'image test2

➤ **Image test 3**




Image originale





Image segmentée



colormap

Figure 33 : Résultat de la segmentation de l'image test3

Le tableau ci-dessous résume les données de la segmentation des images tests

| | Image test1 | Image test2 | Image test3 |
|----------------------|-------------|-------------|-------------|
| Niveau de résolution | 1 | 1 | 1 |
| Nombre de classe | 3 | 4 | 5 |

| | | | |
|---------------------|-----|-----|-----|
| Choix de la fenêtre | 7 | 7 | 7 |
| Le choix de Béta | 0.8 | 0.8 | 0.8 |
| Nombre D'itérations | 20 | 20 | 20 |

Table 3 : Données de la segmentation des images test

b) Deuxième niveau de décomposition

➤ **Image test1**



Image originale

Image segmentée

colormap

Figure 34 : Résultat de la segmentation de l'image test1

➤ **Image test2**




Image originale

Image segmentée

colormap

Figure 35 : Résultat de la segmentation de l'image test2

➤ **Image test 3**






Image originale

Image segmentée

colormap

Figure 36 : Résultat de la segmentation de l'image test 3

Le tableau ci-dessous résume les données de la segmentation des images tests

| | Image test1 | Image test2 | Image test3 |
|----------------------|-------------|-------------|-------------|
| Niveau de résolution | 2 | 2 | 2 |
| Nombre de classe | 3 | 4 | 5 |
| Choix de la fenêtre | 7 | 7 | 9 |
| Le choix de Béta | 0.7 | 0.7 | 0.7 |
| Nombre D'itérations | 10 | 10 | 10 |

Table4 : Données de la segmentation des images test

c) troisième niveau de décomposition

➤ **Image test1**





Image originale

Image segmentée

colormap

Figure 37 : Résultat de la segmentation de l'image test1

➤ **Image test2**





Image originale

Image segmentée

colormap

Figure 38 : Résultat de la segmentation de l'image test2

➤ **Image test3**




Image originale





Image segmentée



colormap

Figure 39 Résultat de la segmentation de l'image test 3

Le tableau ci-dessous résume les données de la segmentation des images tests

| | Image test1 | Image test2 | Image test3 |
|----------------------|-------------|-------------|-------------|
| Niveau de résolution | 3 | 3 | 3 |
| Nombre de classe | 3 | 4 | 5 |
| Choix de la fenêtre | 5 | 5 | 5 |
| Le choix de Béta | 0.5 | 0.5 | 0.5 |
| Nombre D'itérations | 5 | 5 | 5 |

Table5 : Données de la segmentation des images test



V.3.2 Cas des images Météosat

Pour les images Météosat, les résultats de segmentation obtenus sont comme suit :

a) Le premier niveau de décomposition

➤ **Images1**

Avec 7 classes



Avec 8classes







Figure 40 : Résultat de la segmentation de l'image1 avec différentes classes

➤ **Image test2**

Avec 7classes



Avec 8classes





Figure 41 : Résultat de la segmentation de l'image2 avec différentes classes

Le tableau ci-dessous résume les données de la segmentation des images tests


| | Image1(Visible) | | Image2(Infra.R) | |
|----------------------|-----------------|-----|-----------------|-----|
| Niveau de résolution | 1 | 1 | 1 | 1 |
| Nombre de classe | 7 | 8 | 7 | 8 |
| Choix de la fenêtre | 9 | 9 | 9 | 9 |
| Le choix de Béta | 0.8 | 0.8 | 0.8 | 0.8 |
| Nombre D'itérations | 10 | 10 | 10 | 10 |

Table6 : Données de la segmentation des images 1 et 2.

b) Le deuxième niveau de décomposition

➤ **Image1**

Avec 7classes



Avec 8 classes







Figure42 : Résultat de la segmentation de l'image1 avec différentes classes

➤ **Image2**

Avec 7classes



Avec 8classes



Figure 43 : Résultat de la segmentation de l'image2 avec différentes classes

Le tableau ci-dessous résume les données de la segmentation des images tests

| | Image1(Visible) | | Image2(Infra.R) | |
|----------------------|-----------------|-----|-----------------|-----|
| Niveau de résolution | 2 | 2 | 2 | 2 |
| Nombre de classe | 7 | 8 | 7 | 8 |
| Choix de la fenêtre | 7 | 7 | 7 | 7 |
| Le choix de Béta | 0.8 | 0.8 | 0.8 | 0.8 |
| Nombre D'itérations | 10 | 10 | 10 | 10 |

Table7 : Données de la segmentation des images 1 et 2.

c) Troisième niveau de décomposition

➤ **Image1**

Avec 7 classes



Avec 8classes




Figure 44 : Résultat de la segmentation de l'image1 avec différentes classes

➤ **Image2**

Avec 7 classes



Avec 8classes




Figure 45 : Résultat de la segmentation de l'image2 avec différentes classes

Le tableau ci-dessous résume les données de la segmentation des images tests

| | Image1(Visible) | | Image2(Infra) | |
|----------------------|-----------------|-----|---------------|-----|
| Niveau de résolution | 3 | 3 | 3 | 3 |
| Nombre de classe | 7 | 8 | 7 | 8 |
| Choix de la fenêtre | 5 | 5 | 5 | 5 |
| Le choix de Béta | 0.8 | 0.8 | 0.8 | 0.8 |
| Nombre D'itérations | 10 | 10 | 10 | 10 |

Table8 : Données de la segmentation des images 1 et 2.

V.4 Interprétation des résultats

Visiblement, pour les deux types d'images, les résultats de segmentation de niveau de décomposition 1, montrent une bonne discrimination des textures, donc une bonne localisation des contours. En effet, les frontières des régions texturées, ont été parfaitement localisées. Pour rappel, le seul paramètre que nous avons supposé connu est le nombre de classes. Tous les autres paramètres ont été estimés à partir des données observées.

Contrairement aux résultats du niveau1, les résultats de segmentation du niveau 2, montrent une bonne discrimination des textures. Par conséquent, pour les deux types d'images, les régions de textures différentes ont été parfaitement séparées. Seulement une légère délocalisation des frontières entre les différentes textures est constatée sur les images

du niveau 3. Ceci est expliqué par la perte d'informations lors du passage du niveau2 au niveau3.

La qualité de la segmentation Markovienne utilisant la fonction d'énergie E , dépend du choix du paramètre β . Ce dernier correspond au facteur de régularisation de l'homogénéité.

Pratiquement, n'importe quelle valeur entre 0.5 et 1 peut être admise dans notre cas, sachant que la valeur acceptée pour β est comprise entre 0 et 1.

L'augmentation du nombre de classes fait apparaître un excès de détails surtout dans les images météosat, nous sommes alors dans un cas de sur-segmentation.

De plus on remarque que la segmentation markovienne est basée sur la notion du voisinage.

V.5 Discussion

Dans ce travail, nous avons développé une nouvelle approche de segmentation d'images texturées basé sur la transformée en ondelette, l'analyse multi-résolution et les champs de Markov. Notre méthode a été utilisée pour segmenter des images météorologiques. Malgré la complexité des détails composants ces images, les classes dont elles sont constituées ont été bien discriminées. Les résultats expérimentaux ont montré l'efficacité de l'analyse multi-résolution pour la segmentation des images texturées. La satisfaction de nos résultats indique que l'algorithme Markovien est puissant pour des traitements ultérieurs.

Conclusion

La segmentation d'images texturées par les champs de Markov, nous a permis de découvrir le domaine de la télédétection et de connaître le domaine de traitement d'image ainsi que ses différents outils de base depuis l'acquisition de l'image jusqu'au traitement de celle-ci par les différentes méthodes.

Nous avons abordé dans ce mémoire, les trois étapes du traitement statistique d'image qui sont : la modélisation, l'optimisation, et l'estimation des paramètres. Nous avons étudié les problèmes de la segmentation dans un cadre général appelé étiquetage d'image.

Nous avons élaboré un programme de segmentation d'image par les champs de Markov basé sur un modèle multi-résolution, ce dernier, est largement utilisé dans la littérature dans les problèmes d'optimisation formulé dans un cadre bayésien, ce modèle utilise une structure pyramidale et une stratégie descendante lors du processus de minimisation, qu'on a effectuée à l'aide d'un algorithme de minimisation déterministe.

L'avantage du modèle markovien multi-résolution réside dans sa capacité de pouvoir s'affranchir aux faibles résolutions d'un bruit difficilement modélisable, présent dans le domaine original, En effet, l'utilisation de filtres appropriés (associé à une famille d'ondelettes) permet la réduction du bruit aux basses résolutions permettant ainsi l'accès à une bonne configuration initiale du champ des étiquettes.

Quelques types d'ondelettes

Les ondelettes de Haar

Le mérite revient à Alfred Haar d'avoir construit en 1909 des bases considérées aujourd'hui comme le fondement de la théorie des ondelettes. En effet, Haar a défini une fonction $h(x)$

Telle que :

$$h(x) = \begin{cases} 1 & \text{pour } 0 \leq x \leq \frac{1}{2} \\ -1 & \text{pour } \frac{1}{2} \leq x \leq 1 \\ 0 & \text{ailleurs} \end{cases}$$

(A.1)

pour $n \geq 1$, il a construit une base orthonormée de $L^2[0;1]$ avec des fonctions définies par l'équation suivante :

$$h_n(x) = 2^{\frac{j}{2}}(2^j x - k)$$

(A.2)

Avec

$$n = 2^j x + k.$$

$$j \geq 0 \text{ et } 0 \leq k \leq 2^j$$

Dans l'équation ci-dessus, $L^2[0;1]$ est l'espace des fonctions de carré intégrable sur l'intervalle $[0;1]$. Le support de $h_n(x)$ est l'intervalle dynamique défini par l'équation :

$$I_n = [k2^{-j}; (k+1)2^{-j}] \subset [0;1]$$

(A.3)

$h_n(x)$ Peut aussi s'écrire selon l'équation :

$$h_n(x) = 2^{\frac{j}{2}}(2^j x - k) = \frac{1}{\sqrt{2^{-j}}} h\left(\frac{x - k2^{-j}}{2^{-j}}\right)$$

(A.4)




Fig A.1 ; ondelette de Haar

2. Ondelette de Daubechies

Ingrid Daubechies (1990) a complété l'œuvre de Haar en 1987. Pour toute valeur r , Daubechies construit une base orthonormée de $L^2(\mathbb{R})$ de la forme suivante :

$$2^{\frac{j}{2}} \Psi_r(2^j x - k)$$

(A.5)

Où :

$j \in \mathbb{Z}$ et $k \in \mathbb{Z}$

Elle vérifie des les propriétés énoncées plus haut. En effet, Ψ est défini sur un support compact $[0 ; 2r+1]$ et satisfait l'équation ci-dessous :


$$\int_{-\infty}^{+\infty} \Psi_r(x) dx = \int_{-\infty}^{+\infty} x^r \Psi_r(x) dx$$

(A.6)

Où :

$\Psi_r(x)$ Possède r dérivées continues.

Lorsque $r=0$, $\Psi_r(x)$ est défini sur $[0 ; 1]$, on retombe sur le système de Haar (Daubechies « db1 »).



db2

db3

db4

db5

db6

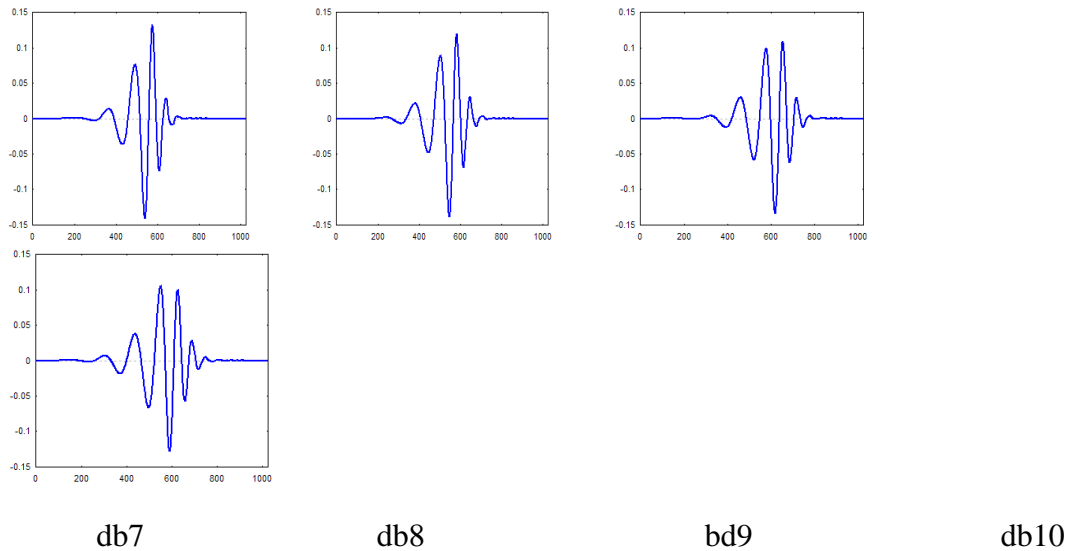


Fig A.2 : exemples d'ondelettes de Daubechies

Remarque : les ondelettes de Haar et de Daubechies font partie du groupe des ondelettes appelées ondelette orthogonales. Ces ondelettes sont des fonctions de base vérifiant les conditions présentées par l'équation :

$$(A.7) \quad \begin{cases} (\Phi_k^j, \Psi_l^j) = \delta_{k,l} \\ (\Psi_k^j, \Psi_l^j) = \delta_{k,l} \end{cases} \quad \text{Pour tout } j, k, l$$

Où :

$\delta_{k,l}$: est défini par l'équation :

$$(A.8) \quad \delta_{k,l} = \begin{cases} 1 & \text{pour } l = k \\ 0 & \text{ailleurs} \end{cases}$$

$\Psi(x)$ et $\Phi(x)$ sont des fonctions permettant de définir respectivement les coefficients des filtres d'analyse passe bas et passe haut de l'ondelette.

3. Ondelettes bi-orthogonales


Pour définir les ondelettes bi-orthogonales, il est nécessaire d'introduire les fonctions duales $\tilde{\Psi}(x)$ et $\tilde{\Phi}(x)$, de $\Psi(x)$ et $\Phi(x)$, respectivement. Les conditions présentées par l'équation ci-dessous sont alors vérifiées :

$$(A.9) \quad \begin{cases} (\Phi_k^j, \tilde{\Phi}_l^j) = \delta_{k,l} \\ (\Psi_k^j, \tilde{\Psi}_l^j) = \delta_{k,l} \end{cases} \quad \text{Avec } \delta_{k,l} = \begin{cases} 1 & \text{pour } l = k \\ 0 & \text{ailleurs} \end{cases}$$


Une ondelette bi-orthogonale est telle que la fonction d'échelle originale est orthogonale à l'ondelette duale et l'ondelette originale est orthogonale à la fonction d'échelle duale.

Autrement dit, les ondelettes bi-orthogonales vérifient les conditions présentées par l'équation :


$$(A.10) \quad \begin{cases} (\Phi_k^j - \tilde{\Phi}_l^j) = 0 \\ (\Psi_k^j - \tilde{\Psi}_l^j) = 0 \end{cases} \quad \text{Pour tout } j, k, l$$



Bior1.3



bior1.5



bior2.6

Fig A.3: exemples d'ondelettes bi-orthogonales.

Bibliographies

[1] Haralick, R.M: *Statistical and structural approaches to texture*, Proceedings of IEEE, Vol. 67, p. 786-804, 1979.

[2] Unser M: *Texture Classification and Segmentation Using Wavelet Frames*, IEEE Trans. On Image Processing, Vol. 4, n°11, p 1549-1560, 1995.

[3] A Gagalowicz : vers un modèle de texture

Thèse de doctorat d'état, université de paris VI, France, Mai 1983.

[4] Driss D : segmentation d'images texturées par la méthode des matrices de cooccurrences : application à des images météo-sat. UMMTO, 2004, (thèse d'ingénieur).

[5] Laws K. I.: *Textured Image Segmentation*. Thesis PhD, University of Southern California, 1980.

[6] Weszka & all: *A comparative study of texture measures for terrain classification*. IEEE Trans. System. Man Cybernetics, Vol 6, p.269-285, 1976.

[7] Saada R: « Segmentation d'images médicales volumétriques par champs de Markov cachés », INI, 2010, (thèse d'ingénieur).

[8] Marion A : *Introduction aux techniques de traitement d'images*. Eyrolles, Paris, 1987

[9] Chaudhvir B.B, Sarkra N : *Texture segmentation using fractal dimension*. IEEE Trans. Pattern Analysis. Machine Intelligence, Vol 17, p .72-77, jan1995.

[10] Canny.J.F: *A computational approach to edge detection*. IEEE Trans. Pattern Analysis and Machine Intelligence, Vol 8 p.769-768, 1986.

[11] Deriche.R : *Optimal edge detection using recursive filters*. In Proc. International Conference on Computer Vision (ICCV'87), London, United Kingdom, p.8-12, 1987.

[12] Chen J. L, Kundu A: *Rotation and gray scale transform invariant texture identification using wavelet decomposition and hidden markov models*. IEEE Trans. Pattern Analysis. Machine Intelligence, Vol 16, p.208-214, Feb1994.

[13] Huang N. K, Gong X : *Textured image recognition using the hidden markov model*. In Proceedings of the Intern. Conf. on Acoustics, Speech and Signal Processing, New York p 1128-1131, April 1988.

[14] A. Rangarajan, R. Chellappa, and B.S. : *Markov random fields and neural networks with applications to early vision problems*. In I. K. Sethi and A.K. Jain, editors, Artificial Neural Networks and Statistical Pattern Recognition. Old and New Connection., J. Elsevier Science Publishers ,p 155-175, 1991.

[15] J. Wang. : *Champs Markoviens multi-échelles: application à la segmentation d'images textures et à la fusion multi-film*. PhD thesis, Université Paris XI Orsay, July 1994.

[16] Kervrann C, Heitz F: *A markov random field model-based approach to unsupervised*

texture segmentation using local and global spatial statistics. IEEE Trans. Image Processing., p856-862, June 1995.

[17] Alouache D : « Segmentation multi-résolution d'images texturées basée sur la transformation en ondelettes : Application aux images Météosat ». UMMTO, 2010, (thèse de MAGISTERE)

[18] P. Bonnin, B. Zavidovique, « La segmentation coopérative : comment combiner détection de contours et croissance de régions ? », quatorzième colloque GRETSI, Juan-les-Pins, pp.755-758, septembre 1993.

[19] Gabor D : *Theory of communication.*, J.IEE (London), Vol. 93, P.429-457 Nov 1946.

[20] Daubechies I, Cohen A, Feauveau J.C : *Biorthogonal bases of compactly supported wavelets*. Communications on pure and applied mathematics, Vol 45, p.485-560, 1992.

[21] Y.Meyer : « Les ondelettes, algorithmes et applications » Armand Colin, 1995

[22] Ayad K : « Compression sans perte d'informations d'Images Médicales Volumétriques Par la Méthode d'Ondelettes », INI, 2007, (thèse d'ingénieur)

[23] S.Mallat «A theory for Multirésolution Signal Decomposition : The Wavelet Representation»

[24] Geman and Geman, 1984: stochastic relaxation, Gibbs distribution, and the Bayesian restoration of images, 'IEEE trans.on Pattern Anal. Machine Intell, vol. 6, n^o4, p.721-741.

[25] Besag, J, 1986 : On the statistical analysis of dirty pictures (with discussion), Journal Royal Statistical Society B, 1986, vol.48, n^o 3, p. 259-302.

[26] Derin et Elliott, 1987 : modeling and Segmentation of Noisy and textured Images using Gibbs Random Fields. *IEEE transactions on Pattern Analysis and machine Intelligence*, vol.PAMI, n^o1, pp.39-55.

[27] Hillion et al., 1989 : le traitement des images de teledetection : aperçus et perspectives Teledetection en francophonie, AUPELF-UREF, John Libbey Eurotext, Paris, p.97-110.

[28] Besag, J, 1974: spacil interaction and the statistical analysis of lattice systems with discussion. *J.Royal Statist. Soc. Sene B*, vol. 26 n^o2, p. 192-236.

[29] Metropoli et al, 1953 : Equation of state calculation by fast computing machines, *The Journal of chemical physics*, 1953, vol. 21, n^o 6, p. 1087-1092.

[30] Chou and Brown, 1990, C.M : the theory and practice of bayesian image labeling, *Int.Journal of computer Vision*, vol. 4, p.185-210.

[31] Kirkpatrick et al., 1983: Optimisation by simulated Annealing. *Science*, vol.200, pp.671-679.

- [33]Ameur Z : « Codage des images en vue d'une segmentation de haut niveau », UMMTO, (thèse de doctorat)
- [34] Mohia Y : « Segmentation d'images par analyse multi-échelle », UMMTO, 2006, (thèse de Magistère)