



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Ecole Nationale Polytechnique

Département d'Electronique

Laboratoire de Télécommunications.

THÈSE

المدرسة الوطنية المتعددة التقنيات
المكتبة — BIBLIOTHEQUE
Ecole Nationale Polytechnique

DE MAGISTER EN ÉLECTRONIQUE
Option : Radar et Télédétection

Présentée par

M^r BOUDAIEB Ahmed

Ingénieur d'état en Électronique à l'E.N.P.

THEME

**APPLICATION DES CHAMPS ALEATOIRES DE MARKOV A
LA SEGMENTATION DES IMAGES RADAR DE TYPE SAR**

Soutenue le 03 Avril 2001 devant la commission d'examen composée de :

M ^{lle} M. Guertí	Maître de Conférences à l'ENP.	Président
M ^r A. Zerguerras	Professeur à l'ENP.	Rapporteur
M ^r C. Larbes	Chargé de recherche à l'ENP.	Examineur
M ^{me} J. Hamami	Chargé de recherche à l'ENP.	Examineur
M ^{me} S. Aït Daoud	Chargé de recherche à l'INI.	Invité

AVANT-PROPOS

LES TRAVAUX présentés dans cette thèse ont été effectués au sein du laboratoire de Télécommunications de l'Ecole Nationale Polytechnique, sous la direction scientifique de Monsieur **A. Zerguerras** Professeur à l'ENP, à qui je présente l'expression de ma profonde gratitude pour tous les conseils et les encouragements qu'ils m'a prodigués pendant toute la durée de ce travail, malgré ses nombreuses occupations.

Je remercie très vivement Madame **M. Guerti** Maître de Conférences à l'ENP, de l'honneur qu'elle me fait en acceptant de juger mon travail et de présider le jury de thèse.

Que Monsieur **C. Larbes** chargé de recherche à l'ENP soit vivement remercié pour l'intérêt qu'il manifeste à ce travail en participant à ce jury de thèse.

Je remercie très vivement Madame **L. Hamami** chargée de recherches à l'E.N.P., je lui exprime mes sincères remerciements pour sa participation au jury de thèse.

Toute notre reconnaissance va à Madame **S. Aït daoud** chargée de recherches à l'E.N.P., nous lui exprimons nos vifs remerciements pour l'intérêt porté aux résultats de ce travail.

Je voudrais témoigner ma reconnaissance aux personnels du centre de documentation de l'ENP pour l'aide, le soutien et l'encouragement qu'ils m'ont offert, en particulier **Krimou, Saleh et Ammi-Mahmoud**. Qu'ils trouvent dans ce modeste travail, le témoignage de ma plus profonde gratitude.

A toutes les personnes (dont le nombre est très élevé pour les citer ici) appartenant ou non à la famille du département d'Electronique, qui ont contribué de près ou de loin, directement ou indirectement à l'aboutissement de ce travail et à l'impression de cette thèse, trouvent ici le témoignage de ma profonde reconnaissance et je les remercie vivement pour leurs aides efficaces.

يهدف هذا العمل إلى تطبيق طريقة التقطيع بمراقبة و بدون مراقبة على صور رادار ذو مجال تركيبي. و لأجل هذا قمنا بتركيب إشارة الرادار مع نموذج أصناف التقطيع. هذا الأخير، أفترض أنه حقل عشوائي لمركوف لكي يسمح لنا بالحصول على دالة توزيع تالية للصورة. التقطيع بمراقبة يعتمد على الخوارزميات العشوائية و المعينة. أما طريقة التقطيع بدون مراقبة فتركز على خوارزمية الأمل الأعظمي و خوارزمية العشوائية المتلائمة، و عليه تم تقدير مختلف الوسائط بأسلوب متناوب. أخيراً، قدمت أمثلة لتوضيح مدى فعالية المنوال المدروس.

كلمات مفتاحية

حقل عشوائي لمركوف، صور رادار ذو مجال تركيبي، خوارزمية الأمل الأعظمي، طريقة التقطيع بدون مراقبة.

Résumé

Un modèle statistique est développé pour la segmentation supervisée et non supervisée des images SAR (Synthetic Aperture Radar). A cet effet, la représentation des données SAR est combinée avec le modèle statistique des classes, fondé sur le champ aléatoire de Markov (MRF) afin d'obtenir une distribution a posteriori. La segmentation supervisée se base sur l'algorithme du recuit simulé qui est de type relaxation aléatoire et les algorithmes ICM (Iterated Conditionals Modes) et MMD (Modified Metropolis Dynamic) qui sont de type relaxation déterministe. La segmentation non supervisée s'appuie sur l'algorithme de l'espérance maximale EM (Expectation-Maximisation) et le recuit simulé adaptatif, dans la mesure où l'estimation des paramètres s'obtient d'une façon itérative. Des exemples illustrent l'efficacité de cette stratégie et sa robustesse au bruit speckle.

Mots clés

Champ aléatoire de Markov, radar à ouverture synthétique, segmentation supervisée, segmentation non supervisée, algorithme recuit simulé, algorithme ICM, algorithme MMD, algorithme EM, algorithme recuit simulé adaptatif.

Abstract

A statistical model is developed for a supervised and unsupervised segmentation of SAR images (Synthetic Aperture Radar). To this effect, the representation of the SAR data is combined with class model. This last model is considered to be a Markov random field in order to get a posteriori distribution to the image. The supervised segmentation use the Simulated Annealing (SA) algorithm and the ICM and MMD algorithms. The unsupervised segmentation is based on the EM algorithm (Expectation-Maximization) and Adaptive SA, that leads to an iterative procedure for parameters estimation. Examples have been provided to illustrate the efficiency of this strategy.

Keywords

Markov random field, synthetic aperture radar, supervised segmentation, unsupervised segmentation, Simulated Annealing algorithm, Iterated Conditionals Modes, Modified Metropolis Dynamic, EM algorithm, adaptive Simulated Annealing algorithm.

SOMMAIRE



CHAPITRE 1 - INTRODUCTION

1. L'imagerie radar	1
2. Les éléments d'interprétation des images radars	2
3. Modèles de texture et champs de Markov	4
4. La segmentation des images	7
5. Estimation des paramètres	8

CHAPITRE 2 - L'IMAGERIE RADAR

Introduction	10
1. Le radar imageur	12
1.1. Généralités.....	12
1.2. Sélection de la fréquence.....	13
1.3. Qualité de l'image.....	13
1.4. Aspect de l'image radar.....	14
1.5. Les applications de l'imagerie radar.....	16
2. Radar à visée latérale	17
2.1. Résolution en distance.....	18
2.2. Résolution azimutale.....	19
3. Radar à ouverture synthétique	20
3.1. L'histoire de la phase.....	20
3.2. Résolution azimutale.....	22
3.3. Traitement SAR du signal.....	23
3.4. Polarimétrie.....	25
3.5. Interférométrie.....	26
3.6. Les erreurs de phase.....	26
4. Les distorsions géométriques des images radar	27
5. Le bruit speckle	27
5.1. Statistiques du bruit speckle.....	28
5.2. méthodes de réduction du speckle.....	29
5.2.1. Traitement multivue.....	29
5.2.2. Filtrage des images SAR.....	31
5.2.3. Mise en œuvre et résultats.....	34
Conclusion	36

CHAPITRE 3 - LES CHAMPS ALEATOIRES DE MARKOV

Introduction	37
1. Jeux différentiels et décision	39
2. Processus aléatoire	39
3. Chaîne de Markov	41
3.1 Processus markovien.....	41
3.2 Chaîne de Markov.....	41
4. Champ aléatoire de Markov	41
4.1. Système de voisinage.....	42
4.2. Champ aléatoire de Markov.....	43
5. Le champ aléatoire de Gibbs (GRF)	43
5.1. Cliques.....	43
5.2. Distribution de Gibbs.....	44
5.3. Probabilités conditionnelles.....	45
6. Fonction D'énergie et fonctions potentielles	46

6.1. Modèle d'Ising	47
6.2. Modèle auto-binomial	47
6.3. Modèle Multi-Level Logistique	48
7. Modèle hiérarchique des images	48
8. Génération des images synthétiques	49
L'échantillonneur de Gibbs	50
9. Conclusion	51



CHAPITRE 4 – SEGMENTATION SUPERVISEE DES IMAGES SAR

Introduction	53
1. Le problème de segmentation	55
3. Le modèle de segmentation	56
4. Algorithmes d'optimisation	58
4.1 Algorithmes stochastiques	59
4.1.1. Algorithmes stochastiques purs	59
4.1.2. Le recuit simulé	59
4.1.3. Température initiale	64
4.2. Algorithmes déterministes	65
4.2.1. Modes conditionnels itérés	66
4.2.2. Dynamique de Metropolis Modifiée	67
5. Mise en œuvre et résultats	68
5.1 Initialisation des étiquettes	68
5.2. Paramètres	68
5.3. Tests	69
6. Conclusion	71

CHAPITRE 5 – SEGMENTATION NON SUPERVISEE DES IMAGES SAR

1. Introduction	76
2. Estimation des paramètres du modèle	78
2.1. Estimation supervisée	78
2.2. Estimation non supervisée	78
3. Estimation des paramètres du bruit	79
4. Estimation des paramètres du champ de Gibbs	80
4.1. Méthode maximum de vraisemblance (MV)	80
4.2. Méthode de codage (CM)	80
4.3. Méthode des moindres carrés (LSQR)	83
5. Segmentation non supervisée	84
5.1. Le problème des Données incomplètes	84
5.2. Algorithme ICE	85
5.3. L'algorithme de recuit simulé adaptatif	86
5.4. L'algorithme EM	87
6. Approche de segmentation avec application de l'algorithme EM	87
6.1. L'étape E : Calcul de l'espérance conditionnelle	88
6.2. L'étape M : Maximisation	90
6.3. Segmentation	92
7. Initialisation des algorithmes de segmentation non supervisée	93
8. Résultats expérimentaux	94
8.1 Estimation des paramètres de Gibbs	94
8.2. Segmentation non supervisée des images SAR	97
9. Conclusion	98

CONCLUSION GENERALE	101
----------------------------------	-----

ANNEXES	103
----------------------	-----

NOTATIONS

β	Paramètre régularisateur
Ω	Espace de toutes les configurations d'une image
ω	Configuration de l'espace Ω
A	L'ensemble des étiquettes
η	Système de voisinage
η_{ij}	Pixels voisins du pixel (i,j)
σ	L'écart type
Φ_g	Vecteur de paramètres de la distribution de Gibbs
Φ_s	Vecteur de paramètres de la distribution du Speckle
EM	Algorithme de l'espérance maximale
ICE	Algorithme de l'estimation conditionnelle
ICM	Algorithme des modes conditionnels itérés
KM	Algorithme des K moyennes
L	L'ensemble des pixels de l'image
M	Nombre de vues d'une image SAR
MMD	Dynamique de Metropolis modifiée
MRF	Champs aléatoires de Markov
N	Nombre total des pixels
RS	Recuit simulé
RSADP	Recuit simulé adaptatif
S.E.R	Surface équivalente Radar
T	Paramètres de température
$U(x)$	Fonction d'énergie
$V_c(x)$	Potentiel de clique c
x	Réalisation de champ et d'étiquette (image segmentée)
X	Champ aléatoire de l'ensemble des étiquettes
y	L'image observée
Y	Champ aléatoire de l'image specklée

1. L'IMAGERIE RADAR

Durant ces dernières années, la science de la télédétection s'est développée d'une manière considérable. A ses débuts la télédétection a été orientée vers les applications militaires et les utilisations civiles étaient limitées. Ce n'est que récemment que le potentiel des satellites d'observations de la terre, associé au développement des techniques liées à la télédétection a permis aux scientifiques et aux planificateurs d'intégrer l'image satellitaire dans leur recherche de solutions à des problèmes de la gestion de l'espace géographique tels que l'aménagement du territoire, l'agriculture, la géologie et autres applications liées à l'environnement.

En télédétection, on distingue deux types de systèmes d'acquisition d'images. Le premier type concernant les systèmes optiques dont le principe est basé sur la quantité de lumière renvoyée par la cible observée. Dans cette catégorie, on trouve à titre d'exemple, les satellites SPOT et LANDSAT qui utilisent le rayonnement solaire pour la production d'image. Ceci limite l'utilisation de ces systèmes dans les mauvaises conditions atmosphériques (brouillard, pluie, nuages,).

Le deuxième type est celui des radars imageurs, qui a pour principe d'illuminer la cible par un rayonnement électromagnétique puis mesurer l'intensité de l'écho réfléchi. L'intérêt essentiel de l'emploi des radars imageurs, par rapport aux capteurs optiques est lié à leur capacité de fonctionnement tout temps. En effet, le radar imageur est un capteur micro-ondes actif, fournit sa propre source d'illumination (rayonnement électromagnétique), permettant ainsi d'obtenir des images aussi bien le jour comme la nuit. En outre, l'effet des turbulences atmosphériques sur l'image radar est tout à fait négligeable[SMA-98], du fait que les ondes pénètrent aisément les nuages et les gouttes de pluie. Contrairement aux radars optiques, l'utilisation des radars imageurs permet

l'accès aux paramètres physiques de la cible, tels que la rugosité de la surface et la constante diélectrique.

Les premières techniques conventionnelles d'imagerie radar ont abouti à des images de qualité médiocre. En fait, la résolution des images obtenues a été limitée, elle s'est dégradée avec la distance et limite celle-ci à quelques kilomètres. Actuellement, et à l'aide de la technique de l'ouverture synthétique (satellites ERS-1, SIR-A,...), on pourra obtenir des images radar de très haute résolution de l'ordre de quelques mètres. Le radar à ouverture synthétique (SAR) permet de synthétiser une antenne effective d'ouverture bien plus grande que celle de l'antenne réelle. Le principe est basé sur le déplacement de l'antenne et le traitement cohérent de la phase des signaux reçus.

Le problème principal rencontré avec l'utilisation du radar SAR, est que les images obtenues sont contaminées par un bruit appelé « speckle ». Généralement, le speckle est un bruit multiplicatif ayant une distribution de Rayleigh ou distribution [DUT-95] [BOV-88][MAT-97][DER-88]. Ce bruit est dû à la sommation cohérente de plusieurs signaux provenant d'un très grand nombre de points diffuseurs. La présence du speckle rend difficile la visualisation et l'interprétation des images. En général, il existe deux méthodes pour réduire l'effet de ce bruit. La première est la méthode multilook (multivues) qui est effectuée pendant la formation de l'image. Elle consiste à moyenniser plusieurs images de la même scène vue de différents angles [THO-84][MOR-96]. La deuxième méthode regroupe toutes les techniques de filtrage de bruit dans une image, à savoir, le filtrage homomorphique, le filtrage heuristique (filtre moyen, le filtre médian, filtre nagao,...) et le filtrage adaptatif [COQ-96][PRA-91][SMA-98] [MAS-94].

Pour exploiter les images radars il importe de développer des outils opérationnels dans le traitement d'image tel que le filtrage, détection de contour et segmentation. En but d'améliorer l'interprétation thématique de l'image radar, il est nécessaire d'intégrer les données optiques avec les données micro-ondes[SOL-96][BEL-98].

2. LES ELEMENTS D'INTERPRETATION DES IMAGES RADARS

Le radar permet d'obtenir des images dont chaque pixel représente l'intensité des signaux réfléchis par une cellule de résolution de la scène. Cette intensité varie en fonction de la rugosité, des propriétés diélectriques et des caractéristiques géométriques de la surface observée. Ainsi, l'aspect de l'image radar est différent de celui de l'image optique. Elle est caractérisée par les paramètres suivants :

- ♦ La radiométrie qui peut être définie comme l'intensité du signal réfléchi par la cible. Les échos de forte intensité apparaissent en clair sur l'image, ceux de faible intensité en foncé.
- ♦ La structure qui est la forme des éléments constituant la scène imagée, telle que les frontières séparant les différentes régions de l'image. Cette caractéristique a une importance fondamentale dans l'analyse des images radar. Les techniques habituellement utilisées pour la mettre en évidence relèvent plutôt de la détection de contours [BOV-88].

♦ La texture qui correspond à la distribution spatiale des différents niveaux de gris, en cela elle est une caractéristique très importante dans l'analyse des images SAR et autres applications. C'est, à partir de la texture que l'on distingue les forêts, les champs d'agriculture, les lacs et autres catégories d'utilisation du sol dans une image SAR. On rencontre deux types de définition de la texture. La première est déterministe et fait référence à une répétition spatiale d'un motif de base dans différentes directions. Cette définition correspond à un type particulier des textures appelé macrotexture. La deuxième est probabiliste et cherche à caractériser l'aspect anarchique et homogène des niveaux de gris dans l'image. Elle correspond à la microtexture. Dans ce travail, nous avons étudié la microtexture et son utilisation dans la segmentation des images SAR. Les différentes composantes de l'image radar ainsi que le bruit speckle sont illustrées à la figure I.1.

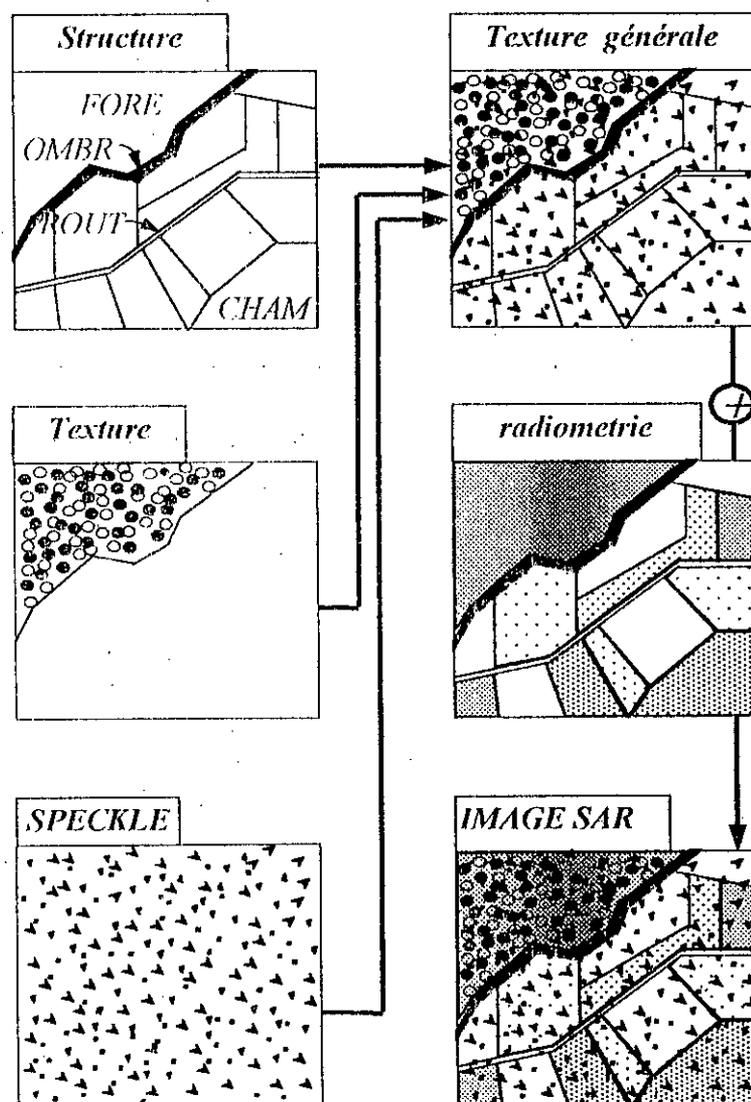


Fig. I.1. Les trois composantes de l'image radar.

3. MODELES DE TEXTURE ET CHAMPS DE MARKOV

La modélisation du contexte de l'image est fonction de la texture visuelle désirée. Ces modèles ont un rôle dual dans la mesure où ils servent à analyser des images réelles et peuvent aussi servir à générer des images synthétiques [JAI-83][CHE-85][JAI-89][BES-89][ELF-96][DER-87]. Ce travail s'intéresse d'un type spécifique des modèles de la texture qui est celui des champs aléatoires de Markov(MRF). Les quatre domaines importants de traitement d'image dans lesquelles la modélisation de la texture joue un rôle important, sont la classification, la segmentation, le codage et la vision par ordinateur.

Il est difficile de définir une texture qualifiée de grossière, de rugueuse, de fine, de périodique et de régulière, et à fortiori de trouver une définition opérationnelle de la texture visuelle qui regroupe toutes ces dimensions perçues. Le manque d'une définition générale précise de texture est traduit par le grand nombre de méthodes d'analyses dans la littérature. Une texture peut être caractérisée par les relations de dépendance qui existent entre les différents niveaux de gris des pixels. C'est pourquoi, La majorité des méthodes de discrimination des textures sont basées sur la corrélation entre les pixels voisins. Les approches principales d'analyse de la texture peuvent être classées dans les catégories suivantes.

- ◆ Méthodes des attributs statistiques de la texture : Une image texturée est représentée comme un ensemble de mesures des vecteurs d'attributs. Quelques attributs célèbres sont basés sur les statistiques locales (la moyenne, la variance et les moments d'ordre supérieur basés sur l'histogramme de la distribution du premier ordre), les statistiques d'ordre deux entre autre la fonction d'autocorrélation, la marge de variation du niveau de gris, l'histogramme de différence de l'image originale et sa version translatée [POS-87], et les matrices de cooccurrence du niveau de gris (l'histogramme de la distribution du deuxième ordre)[HAR-79]. Dans cette catégorie, c'est la matrice de cooccurrence qui est la plus fréquente. Tous ces types des attributs comptent les événements d'une propriété locale simple sur l'image texturée. Les analyses de la texture statistique sont dérivées d'une manière heuristique et l'image originale ne peut pas être recrée à partir de ses attributs.

- ◆ Méthode structurelle : Dans ce cas, la texture est considérée comme un assemblage des formes primitives. Les primitives utilisées sont des formes géométriques variables ou fixes, telles que, hexagone, cercle, courbe, ligne ou même un point. Ce modèle est toujours associé à des règles, appelées grammaire, qui représente les relations existant entre les différentes formes de base. Haralick dans [HAR-79] présente une étude étendue sur les modèles structurels de la texture. Le modèle structurel est convenable pour les macrotecture, mais il n'est pas utilisable pour les microtextures où il est difficile de définir les formes de base et la grammaire.

- ♦ Méthode des microstructures : Le principe de cette méthode est illustré à la figure. I.2

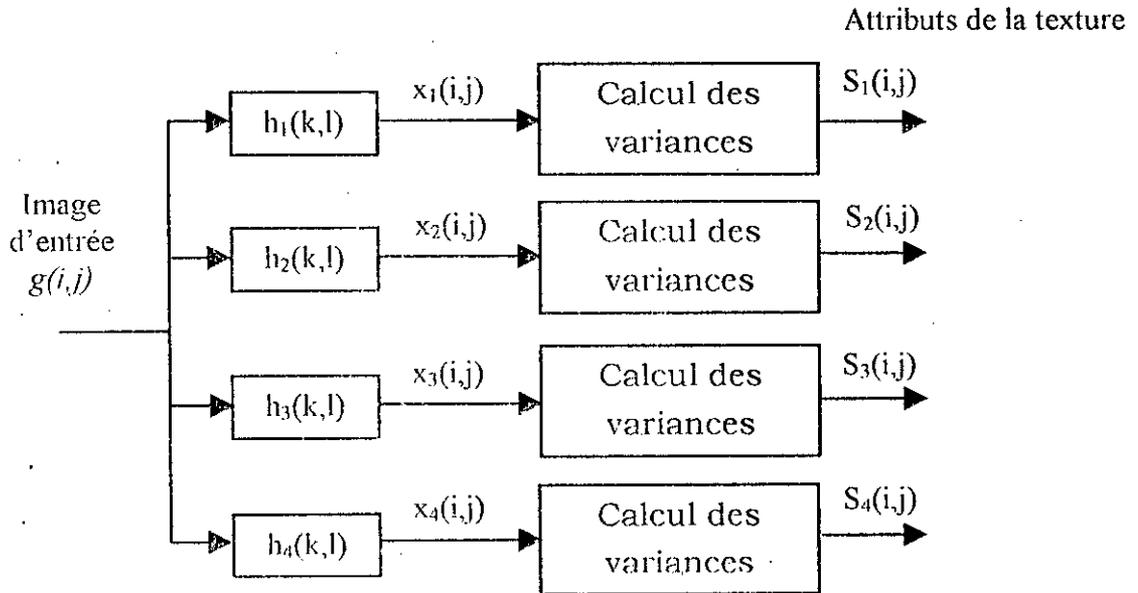


Fig I.2. Méthode d'extraction des attributs de la texture par les masques de Laws

Cette méthode est la base de la stratégie d'extraction des attributs développée par Hsiao [HSI-89]. Elle consiste à calculer l'énergie de texture dans le domaine spatial et nécessite deux étapes : Premièrement, l'image est convoluée avec un ensemble de masques de Laws [HSI-89]. Le produit de convolution de l'image $g(i,j)$ avec le $i^{\text{ème}}$ (h_i) masque est donné par :

$$x_i(i,j) = \sum_{k=-a}^a \sum_{l=-a}^a h_i(k,l)g(i+k,j+l) \quad (I.1)$$

avec $i=j=0,1,\dots,N-1$ et a peut prendre la valeur 1 ou 2.

Ces masques sont synthétisés pour être des filtres adaptés à une certaine variation quasi périodique de la texture [HSI-89]. Deuxièmement, les attributs de la texture (l'énergie de la texture) sont obtenus en formant les matrices de variances locales calculées sur une fenêtre de taille $W \times W$.

- ♦ Méthode spectrale : La méthode spectrale est basée sur la transformée de Fourier bidimensionnelle de l'image [PRA-91][COQ-96][POS-87]. Elle permet d'analyser les variations spatiales et l'orientation de la texture. L'attribut de texture est souvent l'estimateur de la densité spectrale de puissance tel que le périodogramme est donné par l'expression :

$$\hat{S}(f_1, f_2) = \frac{1}{(2M+1)(2N+1)} \left| \sum_{m=-M}^{+M} \sum_{n=-N}^{+N} w(m,n)g(m,n)e^{-2jn(mf_1+nf_2)} \right|^2 \quad (I.2)$$

où M et N sont les dimensions de l'image, $g(m,n)$ est la fonction image et $w(m,n)$ est une fonction de pondération (par exemple la fenêtre de Hanning bidimensionnelle).

Puisque, le degré de grossièreté d'une texture est proportionnel à sa période spatiale, une région de texture grossière doit avoir un spectre d'énergie concentré aux fréquences basses. Inversement, une texture fine doit présente une concentration du spectre d'énergie aux fréquences hautes. Cette méthode permet aussi de déceler la périodicité de la texture. Les expériences précédentes ont montré que cette méthode est mal adaptée aux images naturelles obtenues par les systèmes d'imagerie de télédétection [PRA-91].

♦ Modélisation de la texture : Les modèles statistiques de texture précités sont utiles pour caractériser quelques attributs de textures mais sont incomplets pour d'autres. Toutefois, une autre approche statistique est de modéliser la texture comme une réalisation d'un processus aléatoire 2D (un champ aléatoire). Ce processus est caractérisé par des densités de probabilités jointes ou conditionnelles des variables aléatoires qui composent le champ aléatoire. Ainsi, ce modèle statistique est plus complet parce que tous les autres attributs statistiques peuvent être obtenus, au moins théoriquement, à partir de la densité de probabilité jointe. Comme cette densité est donnée en fonction de quelques paramètres, l'analyse de la texture revient donc à un problème d'estimation des paramètres (i.e. estimer les paramètres du processus aléatoire supposé pour une image texturée donnée) qui peuvent servir comme attributs pour la classification de la texture et les problèmes de la segmentation. Les images texturées synthétiques peuvent être créées par échantillonnage du processus. Une difficulté se présente avec la modélisation de la texture, c'est qu'en général elle ne se conforment pas aux restrictions d'un modèle particulier.

La plupart des études qui ont été élaborées, ont utilisé les champs de Markov comme modèles pour la texture. Ceci est dû au fait que les images texturées sont caractérisées par la dépendance spatiale des pixels voisins. Une telle caractéristique probabiliste est bien exprimée par un processus de Markov. Cross et Jain [CRO-83] ont présenté une étude compréhensive des modèles MRF de texture. Chellappa et Chatterjee [CHE-85] ont utilisé les champs Gauss-Markov (GMRF) pour la classification des textures. Plus récemment, les champs MRF se sont révélés un puissant outil de modélisation dans plusieurs domaines de traitement d'images. Leurs principales applications sont la détection de contours [BLA-87], suivi de la restauration ou du lissage des images [GEM-84], la segmentation des images texturées [DER-87], la classification multisource des images satellitaires [SOL-96], etc.

Le premier avantage d'utilisation des champs de Markov est qu'ils fournissent un modèle mathématique simple, appelé fonction d'énergie, permettant de prendre en compte les différentes contraintes et les données à priori au moyen de la règle de Bayes. Le deuxième avantage des MRF réside dans leur capacité d'exprimer la fonction de probabilité jointe en termes de densités conditionnelles locales, à travers leur formulation comme distribution de Gibbs. Cela a donné naissance un majeur au développement des

algorithmes qui utilisent des calculs locaux pour accomplir l'optimisation globale. Mais l'inconvénient majeur des MRF est le coût de calcul relatif à l'optimisation de la fonction d'énergie. Les algorithmes MRF typiques visitent tous les pixels de l'image dans un ordre spécifique et exécutent un calcul local à chaque pixel, cela est répété jusqu'à ce qu'une convergence soit atteinte. Malgré que les itérations individuelles impliquent seulement des calculs locaux simples, la nature itérative de ces algorithmes augmente le temps de calcul.

Les fonctions d'énergies associées avec la plupart des problèmes MRF non triviaux sont surtout non convexes, ainsi l'utilisation des méthodes basées sur le gradient conventionnel est hors de question. Les meilleurs résultats sont obtenus en utilisant le recuit simulé [KIR-80][GEM-84] qui est une technique de la relaxation stochastique, très coûteuse en temps de calcul. Cet algorithme génère une séquence d'images qui converge vers l'estimateur MAP (Maximum à Posteriori) ou l'estimateur ML (Maximum de Vraisemblance). Le passage d'un état à un autre se fait par un tirage aléatoire. Ce tirage est effectué soit par la dynamique de Métropolis [MET-53] ou par l'échantillonneur de Gibbs [GEM-84]. Pour éviter les maxima locaux, le recuit simulé exige la diminution lente d'un paramètre, appelé température, attaché aux densités conditionnelles locales. Pour réduire le temps de calcul trois solutions ont été proposées : La parallélisation des algorithmes de relaxation [SZI-97], l'utilisation des techniques de multirésolution [KAT-94] [KRI-97][MAT-97] et les algorithmes sous-optimaux de relaxation déterministe tels que ICM (Iterated Conditional Modes) [BES-89] et le GNC (Graduated non-Convexity) [BLA-87]. Ces méthodes convergent vers un maximum local, cependant elles fournissent des bons résultats [FIG-97].

4. LA SEGMENTATION DES IMAGES

La segmentation des images est une tâche essentielle dans l'analyse des scènes et les systèmes de reconnaissance des images. A telle enseigne elle a reçu une attention considérable dans la littérature de vision par ordinateur et de traitement d'image. Le problème de segmentation est de diviser une image donnée en des régions ou segments homogènes qui possèdent des attributs similaires. Chaque région est assignée à une classe parmi un ensemble fini de classes. Cette opération est appelée étiquetage, de manière que chaque classe soit représentée par une étiquette (label). Dans le cas des images texturées, la notion de similitude est relative aux modèles de la texture déjà cités.

Plusieurs techniques ont été proposées dans la littérature pour résoudre le problème de la segmentation. Le choix d'une technique est lié à la nature de l'image; aux opérations situées en aval de la segmentation (interprétation, reconnaissance de formes), aux attributs à extraire et aux contraintes d'exploitation (complexité d'algorithmes, temps de calcul,...). Cependant, il existe une collection de méthodes heuristiques qui ont reçu quelques degrés de popularité durant les dernières années telle que la méthode de croissance de régions (region growing) et la méthode de division et fusion (split and merge) [KUN-93][COQ-96]. Haralick [HAR-79], affirme qu'une bonne segmentation doit avoir les propriétés suivantes :

Les régions de l'image segmentée doivent être uniformes et homogènes par rapport à quelques caractéristiques comme la valeur de niveau de gris et la texture.

1. Les régions doivent être disjointes.
2. Les pixels appartenant à la même région doivent être connectés.
3. Les frontières limitant chaque région doivent être simples, fermées et sans aucune lacune.

Toutes les techniques de segmentation étudiées peuvent être groupées en deux approches globales : l'approche frontière et l'approche région [COQ-96]. Dans l'approche frontière, une région est considérée comme une zone délimitée par un contour. Un tel contour est caractérisé par des variations importantes dans les valeurs des attributs. Cette approche regroupe les techniques de détection de contours. Pour avoir une partition complète de l'image, il faut procéder à une fermeture de contours. Dans l'approche région, une région est considérée comme une zone de l'image dans laquelle les points présentent des propriétés communes. Dans cette thèse, nous nous intéressons à cette dernière approche avec adjonction de la modélisation markovienne. Dans ce cas, le problème de segmentation consiste à assigner à chaque pixel une étiquette pour laquelle la fonction d'énergie soit minimale. La mise à jours des étiquettes est réalisée par les algorithmes de relaxation stochastique ou déterministe.

5. ESTIMATION DES PARAMÈTRES

La qualité des résultats de segmentation par modélisation dépend par un ensemble des paramètres du modèle. Généralement, ces paramètres sont inconnus pour les images réelles et donc on doit les estimer. Ce problème d'estimation a été le sujet de beaucoup de recherches récentes dans l'analyse des images. La plupart des propositions qui ont été faites, sont basées sur les méthodes : de maximum de vraisemblance, moments, pseudo-vraisemblance, codage, etc. [BES-89] [CRO-83] [DUB-89]. Les résultats obtenus sont généralement prometteurs, sans dégager d'une conclusion nette. L'analyse statistique classique favorise la méthode du maximum de vraisemblance du fait que cet estimateur tend à être efficace en convergeant vers la borne de Cram-Rao (C.R.B), au prix d'un énorme calcul.

Dans le cas où le nombre de régions et les paramètres des modèles sont connus a priori, ou font l'objet d'une estimation préalable en se basant sur des échantillons d'apprentissage, la segmentation est dite supervisée. Les résultats de cette technique sont de bonne qualité [RIG-92] [DER-88]. Dans les applications réelles, le nombre de régions et de paramètres sont souvent inconnus, on doit donc les déterminer à partir de l'image observée. Ainsi, Cette situation conduit au problème des données incomplètes. En effet, pour estimer les paramètres on doit disposer d'une réalisation de l'image segmentée et pour faire la segmentation, les paramètres doivent être connus. Pour résoudre ce problème on fait appel aux algorithmes de segmentation non supervisée. Ces algorithmes réalisent l'estimation des paramètres inconnus et la segmentation récursivement. Plusieurs méthodes basées sur cet aspect ont été proposées dans [DER-88] [ZHA-94] [MIG-97].

Ce travail a été organisé de la façon suivante :

Après l'étude des images radar de type SAR et des problèmes rencontrés lors de son acquisition de l'image, sont exposés les méthodes de réduction de speckle avec quelques implémentations de filtres aux performances comparées.

Dans la deuxième partie sont présentées les notions de probabilité en rapport avec le sujet ainsi que les champs de Markov et leur relation avec les images en général.

Dans la troisième partie, les algorithmes d'optimisation nécessaires à la segmentation des images sont établis.

La quatrième partie, est réservée aux méthodes de l'estimation des paramètres et les techniques de segmentation non-supervisée(i.e. : estimation des paramètres après chaque segmentation).

CHAPITRE II

L'IMAGERIE RADAR

INTRODUCTION

En télédétection, les systèmes d'imagerie se subdivisent en deux parties à savoir : les systèmes optiques tels que le LANDSAT et SPOT, et les systèmes micro-ondes passifs (radiomètres) et actifs (Radars). L'acquisition des données dans la bande optique (visible, infrarouge) reste tributaire des conditions atmosphériques (pluie, nuages, brouillard,...) et de l'éclairement de la cible observée (le rayonnement solaire). Ces problèmes peuvent être en partie résolus par les systèmes micro-ondes, et en particulier le radar. En effet, l'atténuation atmosphérique est pratiquement nulle pour les micro-ondes [FAO-89] ($3\text{cm} < \lambda < 30\text{ cm}$). En outre, un senseur micro-onde fournit sa propre source d'illumination (le rayonnement électromagnétique qu'il envoie). Par conséquent, il permet d'obtenir des images aussi bien le jour que la nuit.

L'obtention d'images à haute résolution est très recherchée par les utilisateurs des radars de contrôle aéroportés, du fait qu'elles fournissent plus de détails sur la cible illuminée. Dans les radars conventionnels SLAR (Side Looking Aperture Radar), la résolution en distance (δ_r) est aisément améliorée par le procédé de compression d'impulsion. Cependant, une bonne résolution azimutale (δ_{az}) est difficile à atteindre. Elle devient même impossible aux longues portées, sans l'emploi de grandes antennes de l'ordre du kilomètre. Le radar à ouverture synthétique SAR (Synthetic Aperture Radar) fournit une solution à ce problème d'obtention d'une haute résolution suivant la direction azimut. La technique SAR est utilisée pour atteindre la résolution d'une antenne réseaux très grande à partir du multiplexage d'une petite antenne dans le temps et dans l'espace. Ce multiplexage est associé à un traitement cohérent du signal.

Cet avantage du SAR se fait au prix d'une complexité du traitement effectué lors de l'élaboration de l'image. En plus, le processeur SAR doit comprendre des fonctions pour palier aux phénomènes perturbateurs de l'image entre autre les distorsions radiométriques, les distorsions géométriques, les migrations en distance, les erreurs de phase et le mouvement du porteur.

Comme plusieurs systèmes d'imagerie utilisant le traitement cohérent du signal tel que le Laser, le SAR produit des images contaminées par un bruit appelé speckle. Ce bruit

correspond aux distorsions radiométriques de l'image. Il est dû à la recombinaison en amplitude et en phase des signaux provenant de la multitude des éléments diffuseurs qui forment la surface observée. Ce phénomène rend difficile l'extraction de l'information thématique. Un moyen pour réduire l'effet du speckle est le multivue (multilook en anglais). Ce traitement est effectué pendant la formation de l'image. Il consiste à prendre la moyenne de plusieurs images de la même surface statistiquement indépendantes, vue sous des angles différents.

Cependant la technique multivue a ses limites. Le filtrage constitue un autre moyen pour améliorer la qualité de l'image obtenue, et s'applique après la formation de l'image. Les filtres homomorphiques et les filtres heuristiques (moyen, médian, et EPS (Edge Preserving Smoothing)) sont les plus connus. Des méthodes ont été proposées récemment pour un filtrage optimal, basées sur le modèle statistique du speckle. La plupart de ces méthodes utilisent le modèle du champ aléatoire de Markov (Markov Random Field : MRF). Dans ce cas le problème de filtrage est posé dans le contexte de segmentation.

Un autre problème limitant l'utilité des images radar est les distorsions géométriques. Ces distorsions sont liées à la géométrie de l'acquisition de l'image et les variations du relief terrestre. Le géocodage est une technique connue par les thématiciens, utilisée pour pallier à ce problème. Elle consiste en la correction des distorsions géométriques, en transformant l'image par rapport à une carte topographique de référence.

Ce chapitre est consacré à l'étude de l'image radar : sa qualité, son aspect, la constitution et les distorsions de l'image radar ainsi que les méthodes de correction de ces distorsions. Il traite également du bruit speckle et des méthodes de sa réduction. Enfin, on a donné quelques résultats de filtrage du speckle.

1. LE RADAR IMAGEUR

1.1. Généralités

Un radar imageur fait partie d'une classe d'instruments micro-ondes actifs. Son principe de base est d'envoyer un rayonnement électromagnétique dans un faisceau étroit dans la bande des ondes centimétriques puis mesurer l'écho réfléchi par la cible. Cette mesure est suivie par un traitement numérique du signal afin d'extraire l'information portée par le signal réfléchi (image)(Fig. II.1). Les radars imageurs sont embarqués à bord soit d'un avion (*radar aéroporté*) soit d'un satellite (*radar spatial*).

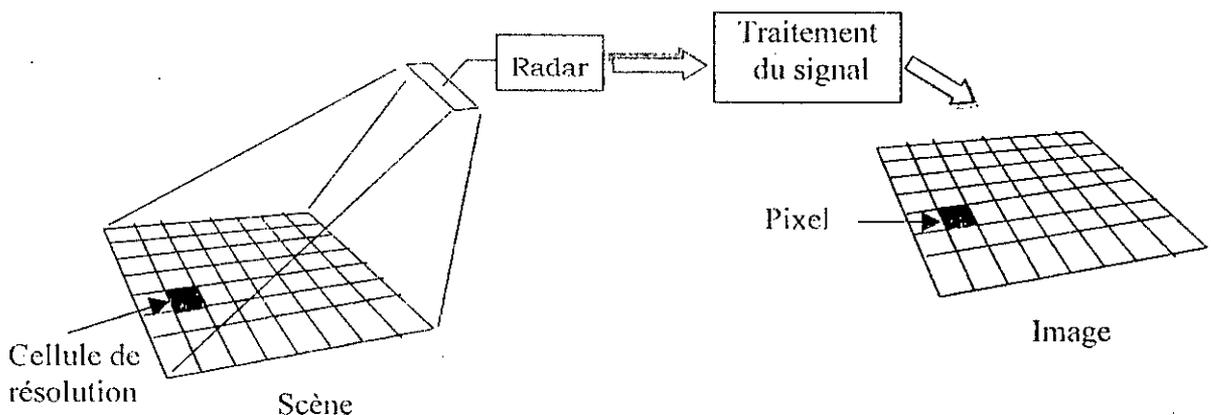


Fig.II.1 Principe du radar imageur

Par rapport aux capteurs optiques l'intérêt de l'emploi des radars imageurs est lié à :

- Sa propre source émettrice (d'éclairement) dans une fréquence donnée, peu affectée par l'atmosphère, il peut travailler de jour comme de nuit sous toutes conditions météorologiques (sauf sous vent de sable).
- Sa possibilité de contrôle de la radiation électromagnétique émise : puissance, fréquence, polarisation et de choisir l'angle d'incidence adapté aux objectifs de l'étude.
- Ses accès aux paramètres physiques et la possibilité d'obtention des informations relatives à la subsurface (constant diélectrique). Cet avantage est dû au pouvoir de pénétration des ondes dans les milieux diélectriques.

Il est à noter que l'image radar est traduite en différents niveaux de gris à partir des échos reçus de la scène étudiée. Contrairement aux systèmes du visible le résultat est souvent bien différent de ce qu'aurait pu voir notre œil s'il avait été à la place du radar.

1.2. Sélection de la fréquence

La bande de fréquence couramment utilisée par le radar imageur, s'étend entre 0,39 GHz et 36GHz. On distingue dans cette bande cinq sous-bandes : la bande L(entre 0,39 GHz et 1,55 GHz), la bande S(entre 1,55 GHz et 3,9 GHz), la bande C(entre 3,9 GHz et 5,75 GHz) la bande X(entre 5,75GHz et 10,9 GHz) et la bande K(entre 10,9 GHz et 36 GHz).

Pour ces bandes, l'interaction onde-surface est très sensible aux propriétés des sols et des océans. Ainsi, vont influencer sur les caractéristiques des signaux reçus, à la fois les propriétés électriques (permittivité, conductivité...) et de structure (rugosité, homogénéité...) des surfaces. Si l'on compare deux images d'une même scène vue dans des bandes différentes, on s'aperçoit tout d'abord qu'elles sont fortement dissemblables du point de vue radiométriques(niveaux de gris) mais aussi des structures présentes(on ne voit pas les mêmes structures sur les deux images). Donc, la bande d'analyse est un paramètre important qui peut permettre de discriminer différentes caractéristiques des objets et des surfaces présentes sur les images.

1.3. Qualité de l'image

Le cahier des charges de la conception d'un radar d'imagerie est déduit de la qualité d'image recherchée. Cette qualité est quantifiée par les critères qui suivent :

1.3.1. La résolution

La résolution est la capacité de discerner deux cibles ponctuelles proches l'une de l'autre dans la direction radiale et la direction azimutale. La figure II.2 représente le module du signal provenant de deux cibles ponctuelles de même surface équivalente radar (SER), à la sortie du récepteur. Celle-ci illustre la définition suivante de la résolution :

La résolution est l'intervalle minimum devant séparer deux cibles ponctuelles, pour qu'un creux supérieur à 3dB sépare les deux pics de corrélation sortant du récepteur adapté.

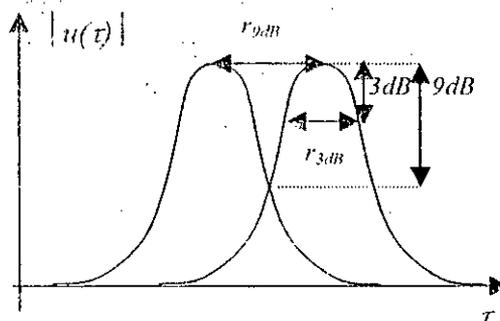


Fig. II.2 Définition de la résolution

1.3.2. Conformité géométrique

La conformité géométrique comprend trois niveaux successifs, qui correspondent à des exigences de plus en plus contraignantes pour le radar et le système dans lequel il est intégré :

1. Précision de localisation relative d'un point par rapport à un autre point sur une même image.
2. Précision de positionnement d'un point d'une image par rapport au porteur du radar.
3. Précision de localisation d'un point d'une image dans un système de coordonnées géographiques.

1.3.3. Résolution radiométrique

La résolution radiométrique est la capacité à discerner deux cibles diffuses dont les coefficients de rétrodiffusion sont voisins (i.e. surface équivalente radar normalisée par rapport la surface d'une cellule de résolution). C'est une mesure de la granulation apparente de l'image, qui est due au bruit speckle.

Elle est quantifiée par le paramètre [HAR-95]

$$\rho = 10 \log \left(1 + \frac{\sigma_p}{\sigma_0} \right) \text{ (dB)} \quad (\text{II.1})$$

où σ_p : est l'écart type du signal plus bruit et σ_0 le coefficient de rétrodiffusion de la cible (la puissance du signal utile).

1.3.4. Conformité radiométrique

Pour pouvoir mesurer des surfaces équivalentes ou des coefficients de rétrodiffusion, il est nécessaire d'étalonner le radar. La connaissance du niveau de bruit et autres parasites est nécessaire pour cette mesure.

1.3.5. Contraste

L'image radar peut être décomposée en deux parties :

- une image utile qui concentre la majeure partie de la puissance,
- une image parasite qui dégrade le contraste.

L'image parasite est induite soit par les pics d'ambiguïtés (de façon décalée, atténuée et déformée) soit par les lobes secondaires du diagramme de rayonnement de l'antenne et les fenêtres utilisées dans le bloc du traitement du signal (Fig II.1).

1.4. Aspect de l'image radar

Un radar imageur produit une image dans laquelle chaque pixel donne une valeur proportionnelle à la puissance du rayonnement électromagnétique rétrodiffusée par la cible. L'équation radar donnant la puissance moyenne rétrodiffusée en tout point de l'image est :

$$P_r = P_t \frac{G \lambda^2 q}{(4\pi)^3 R^4} \sigma_0 \quad (\text{II.2})$$

avec :

P_r : Puissance moyenne reçue

P_t : Puissance transmise

G : Gain d'antenne

λ : Longueur d'onde émise

q : Constante tenant compte des gains et pertes divers.

R : Distance oblique entre l'antenne et la surface imagée

σ_0 : coefficient de rétrodiffusion.

En fait, l'image radar est la représentation de la S.E.R. normalisée de la cible qui est adimensionnelle et s'exprime en décibels à cause de l'étendue de son échelle (qui est de l'ordre de 10^5) :

$$\sigma_{0,db} = 10 \log \sigma_0 \quad (II.3)$$

Cette S.E.R est fonction de :

a. La longueur d'onde

En effet, elle entre en compte dans la profondeur de pénétration de l'onde dans le milieu observé et dans le concept de la rugosité de la surface observée. Pour le satellite ERS-1, par exemple, la longueur d'onde est de 5,66 cm correspondant à une fréquence de 5,3GHz (la bande C).

b. Influence de la polarisation

La polarisation de l'onde électromagnétique est la direction du vecteur champ électrique. Les systèmes imageurs présentent différentes configurations de polarisation. Toutefois, les configurations les plus utilisées sont celles de la polarisation linéaire (les composantes du champ électrique sont liées par une relation linéaire) : HH, VV, HV, VH où la première lettre correspond à la polarisation à l'émission de l'onde, et la deuxième lettre à la polarisation à la réception de l'onde. Lorsqu'un radar possède plusieurs polarisations, il est dit polarimétrique. Pour le satellite ERS-1, il y a une polarisation unique VV.

c. L'angle d'incidence

L'angle d'incidence est l'angle formé par la normale de la surface observée avec la direction de l'onde EM. Il intervient sur la notion de rugosité de la surface. Il peut être fixé ou variable (celui du satellite ERS-1 est fixe et égal à 23°).

d. La rugosité de la surface

La réflexion de l'énergie électromagnétique dépend de la nature et de la forme de la surface observée. La rugosité est donc une notion relative, fonction de la longueur d'onde λ et de l'angle d'incidence θ ou l'angle de dépression δ (Fig. II.3). En effet le critère de Rayleigh fait la distinction entre une surface lisse et une surface rugueuse [MOR-96]. La figure (Fig. II.3). montre deux rayons EM provenant de deux sources distantes S1 et S2 et sont réfléchis par deux surfaces différentes. La différence dans leurs trajectoires aller-retour ΔR ; la distance AOB donnée par :

$$\Delta R = AO + OB = 2h \sin(\delta) - 2h \cos(\theta) \quad (\text{II.4})$$

où h est la hauteur moyenne des irrégularités, ΔR induit un déphasage $\Delta\varphi$ donnée par :

$$\Delta\varphi = \Delta R \frac{2\pi}{\lambda} = \frac{4\pi}{\lambda} \sin(\delta) h \quad (\text{II.5})$$

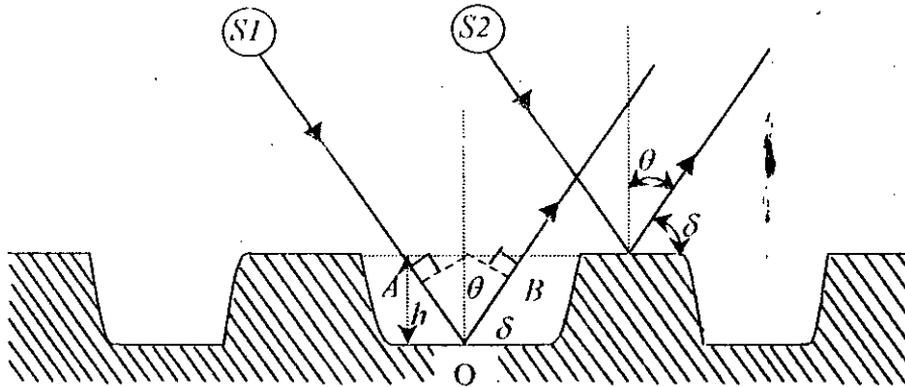


Fig. II.3 Réflexion de surface rugueuse

Pour Rayleigh:

$$\Delta\varphi < \frac{\pi}{2} \quad (\text{II.6})$$

D'où :

$$h < \frac{\lambda}{8 \sin(\delta)} \quad (\text{II.7})$$

e. L'humidité

Celle-ci influe sur les propriétés électriques du sol car la constante diélectrique de l'eau est très élevée. Une surface humide fournira un écho plus fort qu'une surface sèche, dans la même géométrie.

1.5. Les applications de l'imagerie radar

Le radar peut donc fournir des informations sur la texture (rugosité de la surface éclairée par le radar) et sur les paramètres physico-géométriques de la cible (constante diélectrique, forme). Il est utilisé dans le domaine militaire pour la reconnaissance des cibles. Dans le domaine civil, les applications de l'imagerie radar sont nombreuses, une liste non exhaustive est donnée ci-dessous à titre indicatif :

- Surveillance de la végétation : identification des récoltes, suivi de leur évolution, surveillance des forêts et évaluation des surfaces boisées, évaluation de la désertification.
- Surveillance des océans : détection des vagues, détection des pollutions par les hydrocarbures
- Hydrologie : évaluation de l'humidité des sols, cartes des rivières, des étendues d'eau, des zones inondées.
- Cartographie : établissement de cartes et de modèles numériques de terrain (MNT), mesure de glissement de terrain.
- Géologie : mise en évidence des structures géologiques, grâce à la capacité des ondes EM de traverser le couvert végétal.

L'importance de l'imagerie radar se reflète par le nombre de satellites qui lui sont consacrés tels que ERS-1 et ERS-2 pour l'Europe et SIR-A et SIR-B pour les USA.

Les radars imageurs peuvent être de deux types, ceux à visée latérale (SLAR : Side Looking Aperture Radar) et ceux à ouverture synthétique (SAR : Synthetic Aperture Radar). Le premier type (SLAR) se rapporte uniquement à la position d'antenne qui forme un angle de 90° avec la trajectoire du porteur et le second (SAR) est à traitement de signal d'antenne synthétique, même si le radar ne possède pas une antenne latérale.

2. RADAR A VISEE LATERALE

Le radar à visée latérale (SLAR), ou parfois appelé radar à ouverture réelle, est un système d'imagerie plus ancien, utilisé pour la visualisation des cibles. Son principal inconvénient est qu'il possède une basse résolution azimutale et que cette résolution se dégrade avec la portée radar.

La géométrie du radar SLAR est donnée à la figure II.4. Le porteur du radar en mouvement rectiligne vise la cible dans une direction oblique à angle droit avec la ligne

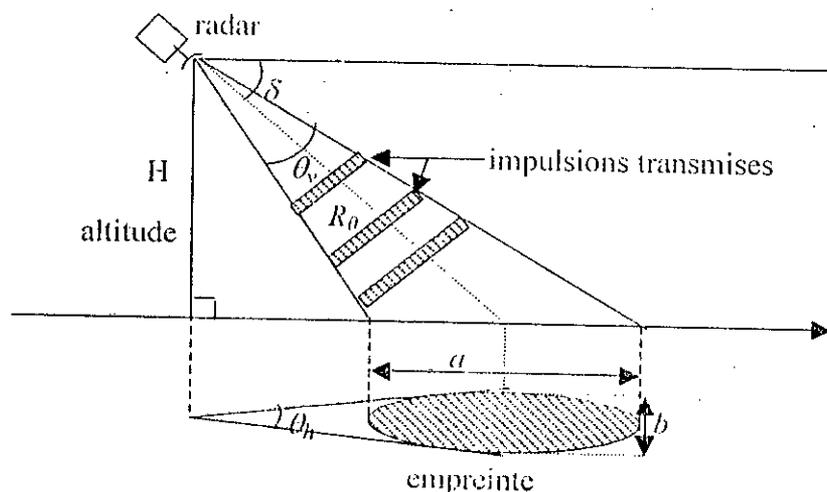


Fig. II.4 Géométrie du radar SLAR.

de vol. Le faisceau depuis l'antenne intercepte une bande de terrain appelée empreinte. Pour une surface plate, cette bande est une ellipse [MOR-96] de rayon longitudinal :

$$a = \frac{R_0 \theta_v}{\sin(\delta)} \quad (\text{II.8})$$

et de rayon transverse :

$$b = R_0 \theta_h \quad (\text{II.9})$$

où θ_h et θ_v sont les angles d'ouvertures à -3dB du diagramme de rayonnement de l'antenne dans la direction horizontale et verticale respectivement et R_0 est la distance oblique. Le déplacement du porteur permet d'obtenir des sous-images de bandes de terrain différentes. Ces sous-images sont juxtaposées dans l'ordre où elles sont obtenues afin de construire l'image complète de terrain. Cette méthode de formation de l'image est appelée *strip-map*.

2.1. Résolution en distance

La résolution en distance ou pouvoir séparateur en distance est la distance minimale entre deux cibles nécessaire à leur séparation par le radar. Si t est le temps écoulé entre l'émission de l'impulsion et la réception de son écho, alors la distance oblique entre le radar et la cible s'écrit :

$$R = \frac{ct}{2} \quad (\text{II.10})$$

où c est la vitesse de la lumière.

Pour que le radar puisse séparer deux cibles très rapprochées et illuminées par le même faisceau, leurs échos doivent nécessairement être reçus à des instants différents. Donc le retard entre la réception des échos doit être au moins égal à la durée de l'impulsion τ_p . D'où la résolution en distance :

$$\delta_r = \frac{c\tau_p}{2} \quad (\text{II.11})$$

Pour un radar observant un terrain horizontal sous un angle de dépression δ (Fig. II.4), la distance projetée au sol W_g , entre les cibles A et B, doit vérifier donc :

$$W_g \geq \frac{c\tau_p}{2\cos(\delta)} = \frac{\delta_r}{\cos(\delta)} \quad (\text{II.12})$$

La résolution en distance est donc d'autant meilleure, que la durée des impulsions τ_p est plus courte. A cet effet, la plupart des radars imageurs utilisent la technique de compression d'impulsion. Cette dernière est basée sur la modulation linéaire de la fréquence de porteuse (i.e. la technique *chirp*) [HAR-95].

2.2. Résolution azimutale

La résolution azimutale est l'angle minimal dans la direction azimut entre deux cibles nécessaire à leur séparation par le radar. Elle est fixée par l'angle d'ouverture à -3dB , θ_h , du faisceau [MOR-96]. La figure II.5 montre que les cibles 1 et 2 sont dans le faisceau radar au même instant et que les signaux réfléchis seront reçus simultanément. Il n'est donc pas possible de les distinguer. Cependant l'écho retourné par la cible 3 est reçu séparément. Par conséquent, pour séparer deux cibles dans le plan azimutal, il est nécessaire que la distance entre elles soit au moins égale à la largeur du faisceau. Pour les radars conventionnels, l'angle d'ouverture à -3dB dans le plan azimutal est donné en radians par : [MOR-96][HAR-95][THO-84]

$$\theta_h = \frac{\lambda}{L_a} \quad (\text{II.13})$$

avec λ est la longueur d'onde et L_a est la longueur effective de l'antenne. La résolution en azimut correspondante, à une distance oblique R_o , est donc :

$$\delta_{cr} = \frac{R_o \lambda}{L_a} \quad (\text{II.14})$$

Un simple exemple numérique nous permet de voir que le radar SLAR ne convient pas aux plates-formes spatiales (satellites). En effet, pour le satellite ERS-1 on a $R_o=800\text{km}$, $\lambda=5,66\text{cm}$ et $L_a=10\text{cm}$, alors $\delta_{cr}=4,5\text{km}$, ce qui n'est pas applicable pour des applications scientifiques qui exigent une imagerie de haute résolution.

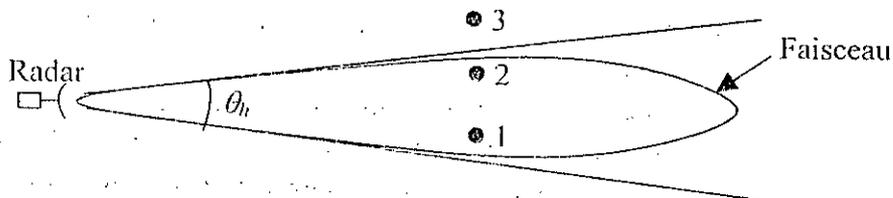


Fig. II.5 Détermination de la résolution azimutale

L'équation (II.14) indique qu'il existe deux façons pour améliorer la résolution azimutale. La première est l'utilisation d'une longueur d'onde plus courte. Néanmoins, il existe des limitations pratiques, en ce qui concerne l'évanouissement rapide des ondes courtes dans l'atmosphère. La deuxième façon consiste à utiliser une antenne très longue. Par exemple, à la fréquence 10GHz une résolution de 5m à la distance 10km nécessite une antenne de 60m de longueur. Une telle antenne ne peut être transportée, d'une manière stable par un avion. Pour ces raisons, le radar à ouverture synthétique est mis au point comme une alternative au radar SLAR.

Il est à noter qu'une cellule de résolution est la surface limitée par δ_r et δ_{cr} (Fig II.1).

3. RADAR A OUVERTURE SYNTHETIQUE

Le radar à ouverture synthétique (SAR) est un système cohérent d'imagerie, aéroporté ou sur satellite, permettant de produire des images 2-D de très haute résolution. Il est basé sur le déplacement d'une petite antenne en des emplacements différents, afin de simuler une antenne réseau plus large. Comme dans le cas du radar SLAR, le SAR utilise des impulsions de courte durée pour améliorer la résolution en distance. La résolution azimutale est améliorée largement par un traitement cohérent de la phase des signaux reçus et enregistrés durant le temps d'illumination de la cible. La résolution azimutale obtenue est comparable à celle qui pourra être atteinte à l'aide d'une très longue antenne. Le principe de base du SAR est décrit à la figure II.6.

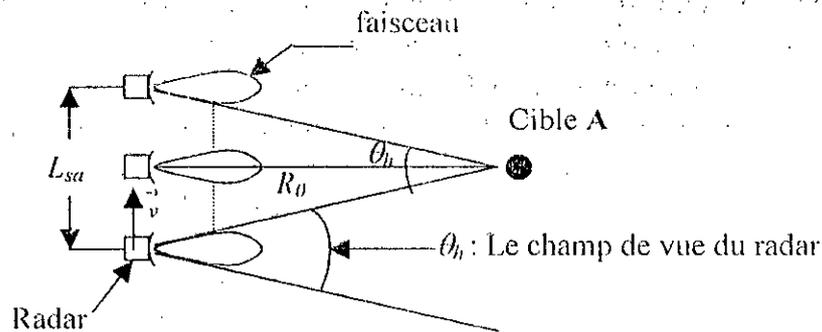


Fig. II.6 Principe de base du radar SAR

Dans cette figure, il est supposé que le radar ayant une antenne latérale (ce qui est souvent le cas) et se déplaçant avec une vitesse constante \vec{v} . Le radar continue à illuminer la même cible A , durant son existence dans le champ de vue. Pendant ce temps, les échos provenant de A sont enregistrés puis additionnés, juste comme un réseau linéaire. Les éléments de ce réseau sont alignés sur une distance L_{sa} appelée *ouverture synthétique*. Elle est liée à l'ouverture réelle θ_h par :

$$L_{sa} = 2R_0 \tan\left(\frac{\theta_h}{2}\right) \cong R_0 \theta_h \quad (\text{II.15})$$

Le temps durant lequel la cible A est éclairée : $T_D = L_{sa}/v$ est appelé le temps d'intégration. D'un emplacement à un autre, la distance entre le radar et la cible changera avec le temps. Par conséquent, les signaux réfléchis par la cible auront des phases différentes. La variation de phase en fonction du temps est appelée *l'histoire de la phase*. L'évolution de la phase est enregistrée pour être utilisée dans les traitements ultérieurs.

3.1. L'histoire de la phase

L'histoire de la phase peut être déduite à partir de la géométrie du radar SAR (figure II.7). Le radar observe la cible P , située dans le plan xy , sous un angle ϕ appelé angle de visée (i.e. l'angle entre la ligne de vol et l'axe de pointage du lobe principal). La cible P peut être

repérée soit par les coordonnées (x, y) ou par les angles de dépression δ et l'angle ψ appelé angle *squint*. A chaque instant la distance $R(t)$ entre le radar et P est donnée par :

$$R(t) = R_0 \sqrt{1 - 2 \cos(\phi) \left(\frac{vt}{R_0}\right) + \left(\frac{vt}{R_0}\right)^2 \sin^2(\phi)} \quad (II.16)$$

Dans les applications courantes, la distance R_0 est très supérieure à l'ouverture synthétique L_{sa} (i.e. $R_0 \gg vT_0$). Alors, on peut faire l'approximation suivante :

$$R(t) \cong R_0 \left[1 - \cos(\phi) \left(\frac{vt}{R_0}\right) + \frac{1}{2} \left(\frac{vt}{R_0}\right)^2 \sin^2(\phi) \right] \quad (II.17)$$

La différence de phase correspondant à la propagation de l'onde sur le trajet aller-retour entre le radar et la cible, s'écrit :

$$\varphi(t) = -\frac{4\pi R(t)}{\lambda} = -\frac{4\pi R_0}{\lambda} + \cos(\phi) \frac{4\pi vt}{\lambda} - \frac{2\pi (vt)^2}{\lambda R_0} \sin^2(\phi) \quad (II.18)$$

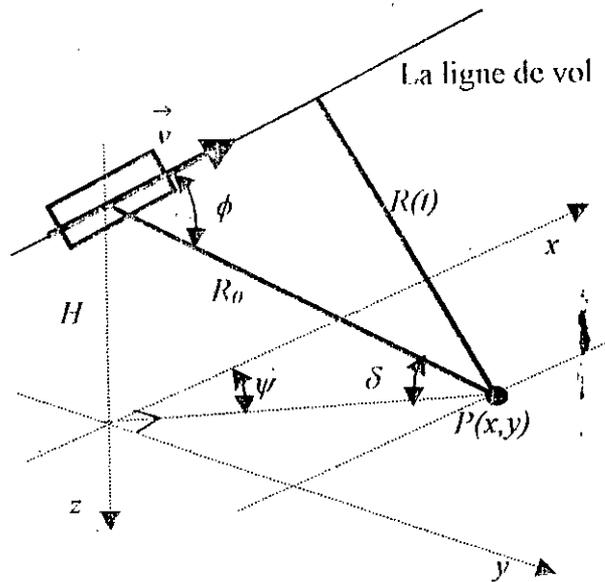


Fig. II.7 Géométrie du radar SAR

L'équation (II.18) montre que l'histoire de la phase est une fonction quadratique par rapport au temps. A partir de (II.18) on déduit l'histoire Doppler qui égale à :

$$f_D(t) = \frac{1}{2\pi} \frac{d\varphi(t)}{dt} = \cos(\phi) \frac{2v}{\lambda} - \frac{2v^2 t}{\lambda R_0} \sin^2(\phi) \quad (II.19)$$

Donc, le signal reçu d'après (II.19) sera modulé linéairement en fréquence (figure II.8), sur une bande B_D (bande Doppler) donnée par :

$$B_D = \frac{2v^2}{\lambda R_0} \sin^2(\phi) T_D \quad (\text{II.20})$$

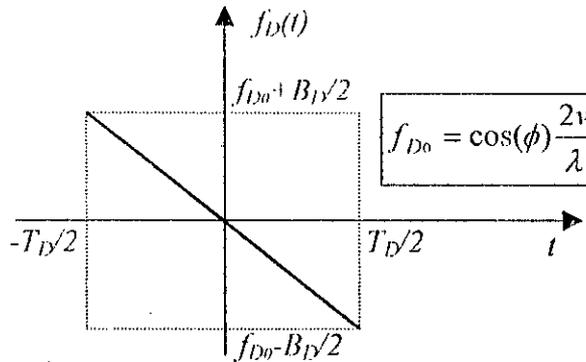


Fig II.8. Variation de la fréquence Doppler pendant l'éclairement

L'histoire de la phase $\varphi(t)$ s'écrit, en fonction de la bande Doppler B_D et la fréquence centrale f_{D0} , donc comme suit :

$$\varphi(t) = \varphi_0 + 2\pi f_{D0}t - \pi \left(\frac{B_D}{T_D} \right) t^2 \quad (\text{II.21})$$

avec $\varphi_0 = -4\pi R_0/\lambda$.

3.2. Résolution azimutale

La résolution azimutale dans le cas du radar SAR est inversement proportionnelle à la bande Doppler B_D [SMA-98] :

$$\delta_{cr} = \frac{v_{az}}{B_D} = \frac{v \sin(\phi)}{B_D} \quad (\text{II.22})$$

avec v_{az} est la composante de vitesse selon la direction azimut.

Nous pouvons ainsi écrire par substitution de l'équation (II.20) dans (II.22) :

$$\delta_{cr} = \frac{\lambda R_0}{2vT_D \sin(\phi)} = \frac{\lambda R_0}{2L_{sa} \sin(\phi)} \quad (\text{II.23})$$

Par l'utilisation des équations (II.13) et (II.15) on obtient :

$$\delta_{cr} = \frac{L_a}{2 \sin(\phi)} \quad (\text{II.24})$$

Pour un radar SAR ayant une antenne latérale ($\phi=90^\circ$), δ_{cr} devient :

$$\delta_{cr} = \frac{L_a}{2} \quad (\text{II.25})$$

On peut remarquer à partir de (II.23) que la résolution azimutale est indépendante :

- De la longueur d'onde : Le radar peut émettre sur n'importe quelle fréquence.
- De la portée radar R_0 : une très haute résolution peut être obtenue même à des centaines de kilomètres (par exemple pour le cas des satellites).
- De la vitesse du porteur : le radar fonctionnera sur un hélicoptère volant à 30m/s comme pour un satellite défilant à 7500m/s.

La résolution azimutale est d'autant meilleure que la longueur effective L_a est petite, contrairement aux radars conventionnels (SLAR). Un radar SAR équipé d'une antenne de 10 m en longueur produira une résolution azimutale de 5m, ce qui est très intéressant.

3.3. Traitement SAR du signal

Le but du traitement SAR est de reconstruire l'image de la scène observée, à partir des nombreuses impulsions réfléchies par la cible. Le principe de ce traitement est basé sur la compensation cohérente de la phase des signaux réfléchis durant le temps d'intégration. Cette compensation est déduite de l'histoire de la phase $\varphi(t)$.

Il existe deux méthodes pour produire l'image finale. La première méthode est celle du traitement optique. Dans ce cas, les signaux réfléchis sont focalisés par une série de lentilles de dimension et de forme différentes. Plus de détails sur cette méthode sont rapportés dans [TOM-78]. La deuxième méthode est basée sur le traitement numérique du signal. Avec cette technique et en utilisant des processeurs rapides, on peut produire des images en temps réel [FAO-89].

Mathématiquement parlant, la compensation de la phase n'est qu'un filtrage adapté appliqué sur le signal reçu [HAR-95].

Le signal émis est :

$$s_0(t) = \sum_{n=-\frac{T_D}{2T_R}}^{\frac{T_D}{2T_R}} u(t - nT_R), \quad t \in \left[-\frac{T_D}{2}, \frac{T_D}{2} \right] \quad (\text{II.26})$$

avec :

$$u(t) = \begin{cases} A_e & 0 \leq t \leq \tau_p \\ 0 & \text{ailleurs} \end{cases} \quad (\text{II.27})$$

et T_R est la période de répétition des impulsions et A_e est leur amplitude.

Le signal reçu, après démodulation par la fréquence porteuse hyperfréquence, s'obtient en introduisant l'histoire de la phase $\varphi(t)$:

$$s(t) = \sum_{n=-\frac{T_D}{2T_R}}^{\frac{T_D}{2T_R}} u(t - nT_R - \frac{2R(t)}{c}) e^{j\varphi(t)}, \quad t \in \left[-\frac{T_D}{2}, \frac{T_D}{2} \right] \quad (\text{II.28})$$

Dans cette expression, nous avons négligé l'effet du lobe principal de l'antenne sur l'amplitude des impulsions.

Pour chaque cellule de résolution (i,j) , le processeur SAR effectue un filtrage adapté au signal reçu. Le signal issu du traitement est donc la convolution du signal reçu avec la réponse impulsionnelle $h(t)$ du filtre adapté, appelée aussi fonction de référence.

D'après la théorie du filtre adapté [SPA-87], $h(t)$ est donnée par :

$$h(t) = s^*(t) \quad (\text{II.29})$$

avec * signifie l'opération de conjugué.

Alors le signal de sortie est :

$$c(\tau) = \int_e s(t) s^*(t - \tau) dt \quad (\text{II.30})$$

La plupart des applications s'intéressent au calcul du module du signal $c(\tau)$, qui est suffisant. Pour certains traitements, tels la polarimétrie et l'interférométrie, le calcul de phase est aussi nécessaire.

Le schéma simplifié du traitement SAR est donné à la figure(II.9) :



Fig. II.9 Formation de l'image radar

Un exemple d'une image SAR, captée par le satellite ERS-1 est donnée à la figure II.10.

L'image SAR ainsi formée est un tableau temps-distance où le temps(ligne) est représenté par le cadencement des impulsions et la distance(colonne) par la position d'un écho sur une ligne.

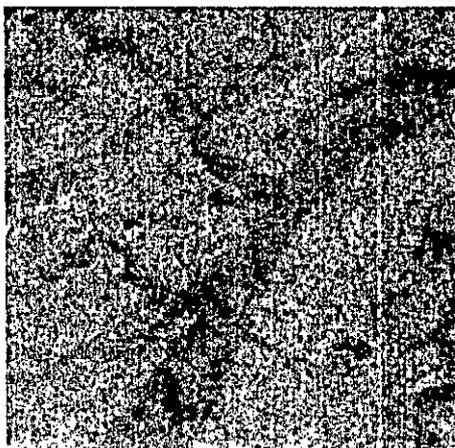


Fig. II.10 Image radar d'une région de Laghouat

3.4. Polarimétrie

Les radars usuels tels que ceux de ERS-1 ou ERS-2 utilisent la même configuration de polarisation de l'antenne aussi bien pour la transmission que pour la réception de l'onde électromagnétique et opèrent à une polarisation fixe. Ces systèmes n'autorisent pas une caractérisation complète des mécanismes d'interaction de l'onde électromagnétique avec la cible. Dans les années récentes, des radars travaillant avec toutes les configurations de polarisation (HH , VV , HV , VH), appelés radars polarimétriques, ont été développés pour acquérir toute l'information contenue dans la réponse du radar.

Le champ électrique est décomposé en deux composantes orthogonales, E_H et E_V (figure II.11), qui sont reçus et traités indépendamment dans des canaux séparés. En utilisant plusieurs combinaisons de polarisation horizontale et /ou verticale de l'émission et de la réception, une matrice de rétrodiffusion est mesurée pour chaque cellule de résolution.

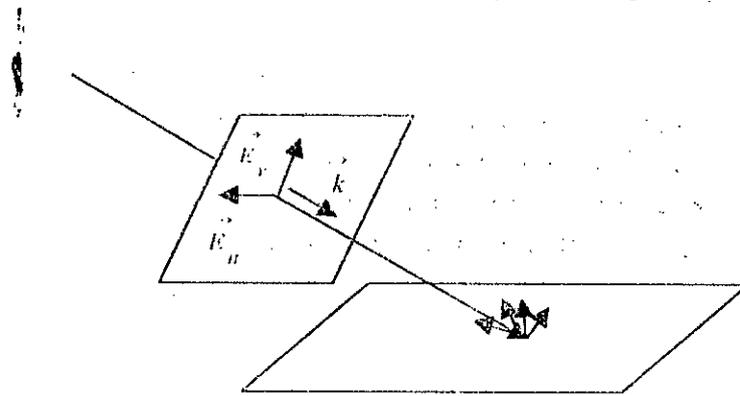


Fig. II.11 Définition des composantes horizontale et verticale du champ.

La matrice de rétrodiffusion qui relie le champ électrique incident, reçu par la cible, et le champ électrique réfléchi, mesuré par le radar, est donnée par :

$$\begin{pmatrix} E'_V \\ E'_H \end{pmatrix} = \begin{pmatrix} S_{VV} & S_{VH} \\ S_{HV} & S_{HH} \end{pmatrix} \begin{pmatrix} E_V \\ E_H \end{pmatrix} \quad (\text{II.31})$$

Les éléments S_{pq} sont les surfaces équivalentes radar en polarisation indiquée par pq . La connaissance de ces éléments permet de synthétiser tout type de configuration de la polarisation, et étudier la variation du module et de la phase de l'onde réfléchie avec la polarisation

Le radar polarimétrique SAR permet de comprendre et de mesurer les propriétés de dispersion des cibles et leur variabilité sous diverses conditions spécifiques. Ceci conduit à une bonne discrimination des différents types de terrain entre eux à partir des matrices de rétrodiffusion et donc une segmentation de la zone d'étude en plusieurs régions [RIG-92].

3.5. Interférométrie

Les nouveaux développements du SAR résident dans la capacité d'obtention d'images tridimensionnelles (3D) «en profondeur» par l'utilisation de la technique d'interférométrie, appelée IFSAR. Cette technique est basée sur l'emploi de deux images complexes reçues par deux antennes séparées par une distance b et situées à une altitude Z par rapport à un plan de référence choisi arbitrairement (figure II.12).

Si on note par $s_1(m,n)$ et $s_2(m,n)$ les deux images complexes, alors la première étape consiste à mesurer la différence de phase (interférogramme) entre les signaux reçus par les deux antennes :

$$\Delta\varphi(m,n) = \arg(s_1(m,n)s_2^*(m,n)) \pmod{2\pi} \quad (\text{II.32})$$

L'estimée de la hauteur Δh de chaque pixel relativement au plan référence est donnée approximativement par [MOR-96] :

$$\Delta h(m,n) \cong - \left[\frac{Z \cot(\psi)}{4\pi b \sin(\psi)} \right] \Delta\varphi(m,n) \quad (\text{II.33})$$

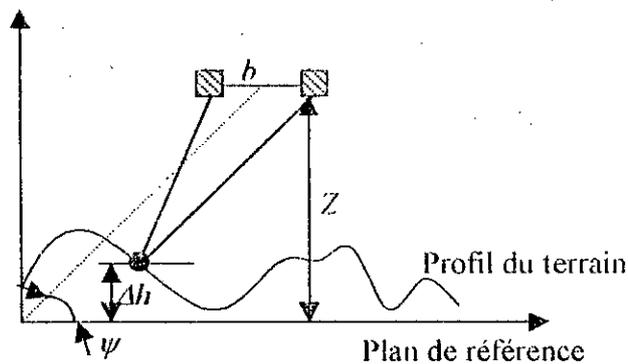


Fig. II.12 Géométrie du radar IFSAR

La différence de phase $\Delta\varphi$ est définie à 2π près, ce qui entraîne une ambiguïté sur la mesure de Δh . Des méthodes de compensations se sont avérées nécessaires pour enlever cette ambiguïté.

3.6. Les erreurs de phase

Puisque le radar SAR est un système d'imagerie cohérent, la production d'images de haute qualité suppose que le radar génère des histoires de phase exactes de la cible ainsi que les fonctions de référence. Cette supposition n'est pas toujours vraie, elle est perturbée par :

- Les mouvements parasites du porteur pendant la prise d'image.
- Les instabilités de la source de fréquence et de l'émetteur du radar.
- L'imprécision sur les paramètres qui servent au calcul de la fonction de référence.

Ces perturbations constituent l'erreur de phase $\varepsilon(t)$, qui s'ajoute à la phase idéale (II.21)

$$\varphi_r(t) = \varphi(t) + \varepsilon(t) \quad (\text{II.34})$$

Les erreurs de phase interviennent surtout dans la conformité géométrique et le contraste de l'image [HAR-95]. Elles peuvent être minimisées par l'utilisation des données du système de navigation inertiel (INS) pour la poursuite des déviations par rapport aux données nominales (vitesse et altitude constantes) [MOR-96]. Une autre approche pour compenser les erreurs de phase est l'autofocalisation qui estime l'erreur $\varepsilon(t)$ par des algorithmes itératifs tel que celui du gradient [MOR-96].

4. LES DISTORSIONS GEOMETRIQUES DES IMAGES RADAR

Les images acquises par le radar présentent plusieurs types de déformations géométriques [JAQ-97] (zones d'ombre et zones d'inversion), qui sont dues essentiellement aux facteurs suivants :

- Problème de la localisation de la cible.
- Erreurs induites dans le traitement du signal.
- La géométrie de l'acquisition de l'image.

Dans de nombreuses situations ces distortions limitent considérablement l'utilité des images radar. Le *géocodage* est une technique qui permet de minimiser et corriger de telles distortions [BEL-98][SMA-98] par la géométrie de l'image relativement à une carte topographique ou une image de référence. En effet, géocoder une image consiste à introduire des corrections sur l'image originale afin que la distribution spatiale des points de l'image finale corresponde à celle d'une projection cartographique donnée. A ce sujet, les agences spatiales internationales ont opté pour une harmonisation de l'utilisation des grilles de références telles que la grille UTM « Universal Transversal Mercator » ainsi que la grille UPS « Universal Polar Stereographic ». Ces deux grilles utilisent généralement, le système WGS 84 « World Geodetic System » comme ellipsoïde terrestre de référence. Un système de géocodage des images SAR comprend trois bases de données : les paramètres orbitaux, données de radars brutes et une donnée géographique (modèle numérique de terrain (MNT), points d'appui et paramètres de projection cartographique).

Comme ces données ne sont pas toujours disponibles au niveau des utilisateurs, alors nous avons supposé dans ce travail que les images utilisées sont géocodées.

5. LE BRUIT SPECKLE

Comme tout système d'imagerie cohérent, le radar SAR produit des images contaminées par le *speckle*, un bruit multiplicatif issu de la combinaison cohérente des échos de la multitude de points diffuseurs pour former un point image. Si la distribution de l'amplitude du signal reçu est Gaussienne et celle de sa phase uniforme, alors l'amplitude (niveau de gris) du point image sera distribuée selon la loi de Rayleigh donc, les pixels qui représentent des régions avec la même RCS, peuvent posséder des niveaux de gris différents. Ces variations ne sont pas dues à un bruit thermique, à la quantification, ou à toute autre source de bruit, mais sont considérées comme bruit à

cause de leur effet sur la qualité d'image. En effet, elles donnent un aspect granuleux à l'image radar. Le bruit speckle intervient également dans la résolution radiométrique.

5.1. Statistiques du bruit speckle

Comme nous l'avons vu déjà, chaque pixel de l'image est représenté par l'amplitude du signal rétrodiffusé par la surface étudiée. La zone imagée est supposée être constituée avec un très grand nombre de diffuseurs élémentaires. A un site(pixel) l'écho radar est donc la somme des signaux réfléchis par les diffuseurs élémentaires contenus dans une cellule de résolution. Ainsi, l'amplitude complexe du signal reçu est :

$$Z = Y e^{j\phi} = \sum_{k=1}^N a_k e^{j\phi_k} \quad (II.35)$$

où a_k et ϕ_k sont respectivement l'amplitude et la phase associés au $k^{\text{ème}}$ diffuseur et N est le nombre des diffuseurs dans une cellule de résolution.

La répartition aléatoire des diffuseurs au sein d'une cellule de résolution, ainsi que les variations de leurs caractéristiques électromagnétiques, font que a_k et ϕ_k sont des variables aléatoires. Par conséquent, les interférences entre ces signaux granulent l'image (chatoiement ou speckle). Si on admet que pour chaque diffuseur a_k et ϕ_k sont indépendants, les ϕ_k sont uniformément distribuées sur $[-\pi, \pi]$ et si le nombre de diffuseurs est grand lorsque ($N \rightarrow \infty$), on peut montrer par l'utilisation du théorème centrale limite que la partie réelle de Z , $Re[Z]=Z_R$, et la partie imaginaire de Z , $IM[Z]=Z_I$, sont des variables aléatoires gaussiennes non corrélées ($E(Z_R Z_I)=0$) et de moyennes nulles. Dans l'image amplitude, le niveau de gris observé à un pixel est le module de l'amplitude complexe Z :

$$Y = \sqrt{Z_R^2 + Z_I^2} \quad (II.36)$$

On peut montrer que la variable aléatoire Y suit une loi de probabilité de Rayleigh donnée par :

$$P_Y(y) = \begin{cases} \frac{y}{\sigma^2} e^{-\frac{y^2}{2\sigma^2}} & \text{si } y \geq 0 \\ 0 & \text{sinon} \end{cases} \quad (II.37)$$

où σ est l'écart type de Z_R et Z_I , soit $\sigma^2 = var(Y)$.

Si on considère une image d'intensité : $I=Y^2$, le signal reçu suit alors une distribution exponentielle de la forme :

$$P_I(i) = \begin{cases} \frac{1}{2\sigma^2} e^{-\frac{i}{2\sigma^2}} & \text{si } i \geq 0 \\ 0 & \text{sinon} \end{cases} \quad (II.38)$$

Une telle image est dite monovue (1-look). En pratique, on est amené parfois à faire le moyennage de plusieurs images de la même surface, vues sous plusieurs angles (image multivues : M-looks), afin de réduire le niveau de fluctuation du speckle. Si M

réalisations indépendantes sont moyennées, alors à chaque pixel on observe l'intensité moyenne :

$$V = \frac{1}{M} \sum_{l=1}^M I_l \quad (\text{II.39})$$

Où I_l est l'image intensité 1-look. Dans ce cas, la probabilité conditionnelle V est celle de Gamma[DER-87], définie par :

$$P_V(v) = \begin{cases} \frac{v^{M-1} e^{-\frac{v}{2\sigma^2}}}{(M-1)! \left(\frac{2\sigma^2}{M}\right)^M} & \text{si } v \geq 0 \\ 0 & \text{sinon} \end{cases} \quad (\text{II.40})$$

Notant que $E(V)=2\sigma^2$, tant que, $E(V)/[Var(V)]^{1/2} = M^{1/2}$, ainsi l'écart type est proportionnel à la valeur moyenne. Par conséquent, le speckle est un bruit multiplicatif. L'image amplitude M-looks s'écrit :

$$Y_M = \sqrt{V} = \left(\frac{1}{M} \sum_{l=1}^M I_l \right)^{\frac{1}{2}} \quad (\text{II.41})$$

Ainsi, la distribution de probabilité de Y_M est donc :

$$P_{Y_M}(y_M) = \begin{cases} 2 \frac{y_M^{2M-1} e^{-\frac{y_M^2}{2\sigma^2}}}{(M-1)! \left(\frac{2\sigma^2}{M}\right)^M} & \text{si } y_M \geq 0 \\ 0 & \text{sinon} \end{cases} \quad (\text{II.42})$$

Il est à noter que la distribution de l'image monovue est un cas particulier de celle de l'image M-looks pour $M=1$.

5.2. Méthodes de réduction du speckle

La réduction de speckle permet d'améliorer la résolution radiométrique et rend possible l'application sur une image radar des méthodes classiques d'interprétation ainsi que son intégration avec d'autres types de données (classification multisource).

En général, il existe deux moyens pour la réduction du niveau de fluctuation du speckle, qui sont la technique multivue et la technique conventionnelle de filtrage.

5.2.1. Traitement multivue

La technique multivue est appliquée généralement dès la production de l'image. Son principe consiste à moyennner un nombre N d'échantillons indépendantes du speckle, ce qui a pour effet de réduire les fluctuations du bruit. L'image obtenue est appelée image N-look. Cette opération peut s'effectuer de deux manières différentes :

5.2.1.1. Spectralement

En divisant l'ouverture synthétique L_{sa} en N segments, ce qui traduit par la division de la bande Doppler B_D en N sous-bandes comme le montrent les figures II.13 et II.14. Par conséquent, N images sont formées séparément et indépendamment. Ces images sont additionnées pour former l'image finale. Ceci a pour effet de dégrader la résolution azimutale d'un facteur égale à N .

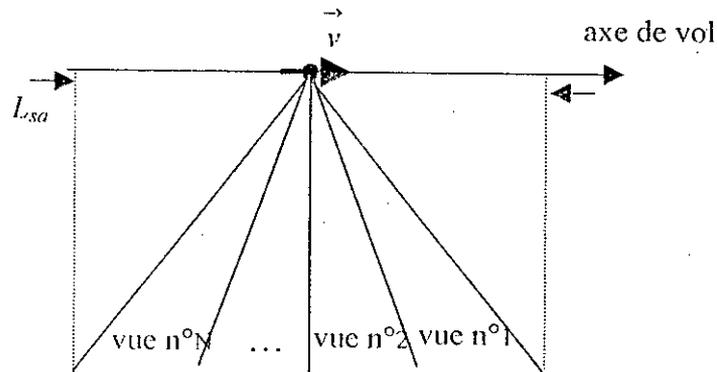
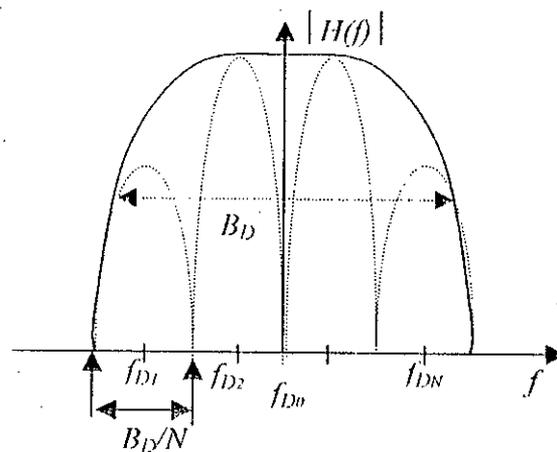


Fig. II.13 Traitement multivue



$H(f)$: transformée de Fourier de $h(t)$

Fig. II.14 Séparation de la bande Doppler en N sous bandes

5.2.1.2. spatialement

En effectuant la moyenne de N pixels adjacents de l'image pleine résolution (image 1 look) pour former un pixel de basse résolution comme le montre la figure II.15. Dans cette figure, chaque quatre pixels adjacents sont remplacés par leur moyenne. Ce traitement est appliqué sur toute l'image et chaque pixel est utilisé une seule fois.

Plus le nombre de vues (looks) est grand, plus le speckle est atténué. Toutefois, cette technique a l'inconvénient de dégrader la résolution spatiale de l'image ; il faut donc faire un compromis entre la résolution spatiale et la réduction du speckle.

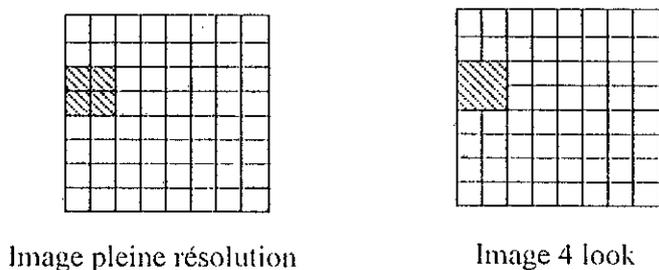


Fig. II.15 Réduction spatiale du speckle

5.2.2. Filtrage des images SAR

Malgré le traitement multivue, la faible résolution radiométrique observée sur les images SAR rend difficile l'interprétation et l'analyse de ces images. Un filtrage supplémentaire s'avère donc nécessaire. Cette étape de traitement entre dans le cadre des traitements thématiques de l'image radar, et vient après que l'image ait été formée.

Plusieurs filtres ont été développés depuis une quinzaine d'années pour réduire le niveau de fluctuation du speckle certains d'entre eux seront donnés par la suite.

5.2.2.1. Filtres homomorphiques

A cause de la nature multiplicative du bruit speckle (voir § II.5), ces filtres sont souvent utilisés pour améliorer la résolution radiométrique des images specklées. Ils transforment un bruit multiplicatif en un bruit additif à l'aide d'une opération logarithmique.

Supposons le modèle multiplicatif suivant :

$$y = xb \quad (\text{II.43})$$

Où y représente l'image observée, x l'image non bruitée et b le bruit multiplicatif (speckle). En effectuant l'opération logarithmique on obtient :

$$\log(y) = \log(x) + \log(b) \quad (\text{II.44})$$

Si on pose :

$$y_l = \log(y), \quad x_l = \log(x), \quad b_l = \log(b)$$

il vient :

$$y_l = x_l + b_l \quad (\text{II.45})$$

D'après (II.45), on voit que b_l peut être traité donc comme un bruit additif. Pour cet effet on utilise les méthodes classiques tel que le filtrage de Wiener et le filtre d'Arsenault [SMA-98].

Cependant ces filtres présentent deux inconvénients majeurs. L'un est, la difficulté numérique qui survient pour les valeurs proches de zéro. Le deuxième, est que la fonction de la densité de probabilité (fdp) du signal transformé n'est plus gaussienne, bien que la plupart des techniques du filtrage classique sont optimales pour la distribution gaussienne [MAT-97].

5.2.2.2. Filtres heuristiques

Ce sont des méthodes qui ne tiennent pas compte du modèle statistique du bruit. Parmi ces filtres, on trouve :

a)Le filtre moyen : Il consiste à faire glisser une fenêtre de taille $m \times n$, sur toute l'image. La valeur du pixel à traiter (pixel central de la fenêtre) est remplacée par la moyenne des pixels qui sont à l'intérieur de cette fenêtre. L'inconvénient de ce filtre c'est qu'il donne une image floue. En effet, ce filtrage provoque la distorsion des frontières qui séparent des régions homogènes.

b)Le filtre médian Comme le filtre moyen, le filtre médian utilise une fenêtre glissante, balayant toute l'image. En premier, les pixels masqués par cette fenêtre, sont rangés en ordre croissant. En deuxième, le pixel central est remplacé par celui du milieu de cette suite ordonnée (la médiane). Ce filtre ne permet pas de filtrer sélectivement les variations du speckle tout en préservant les réponses radar d'objets isolés de petites dimensions.

c)Le filtre EPS(Edge Preserving Smoothing) : Ce type de filtrage a été utilisé pour la première fois par Nagao et Matsuyama [NAG-80]. Son principe est de lisser le bruit à l'intérieur des régions homogènes sans noyer les contours qui les séparent. Il consiste à définir une fenêtre carrée de dimension $n \times n$ autour du pixel (i,j) qu'on veut filtrer, contenant neuf (09) masques de taille $w \times w$ (voir figure II.16). A l'intérieur de chaque masque on calcule la moyenne et la variance.

La moyenne est donnée par :

$$m_i = \frac{1}{w^2} \sum_{k=0}^{w-1} \sum_{l=0}^{w-1} y(k,l) \quad i = \overline{1,9} \quad (\text{II.46})$$

et la variance par :

$$v_i = \frac{1}{w^2} \sum_{k=0}^{w-1} \sum_{l=0}^{w-1} [y(k,l) - m_i]^2 \quad i = \overline{1,9} \quad (\text{II.47})$$

On choisit par la suite le masque le plus homogène (qui correspond à la variance minimale) pour remplacer la valeur du pixel qui vient d'être traité par la moyenne de ce masque.

Le bruit est éliminé par l'application successive de ce filtre sur toute l'image pendant un nombre d'itérations déterminé ou jusqu'à ce qu'un critère de stabilité soit vérifié. Par exemple dans [MAS-94] on trouve le critère suivant :

Si $\sum_{(i,j)} |\hat{x}_k(i,j) - \hat{x}_{k-1}(i,j)| \leq T$ alors la stabilité est atteinte. où T est le seuil de stabilité, et

\hat{x}_k est l'image estimée à l'itération k .

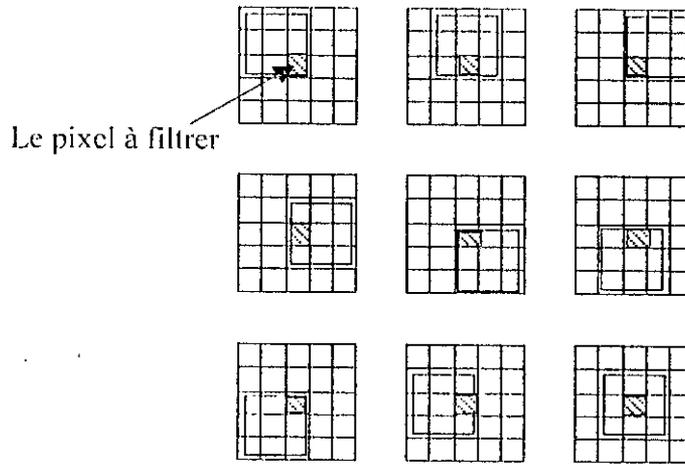


Fig. II.16 les 09 masques du filtre de Nagao et Matsuyama pour une fenêtre 5x5

5.2.2.3. Filtres adaptatifs

Cette classe de filtres tente de tenir compte de la spécificité du bruit et des propriétés statistiques des images SAR. Les filtres adaptatifs consistent donc, à construire un modèle de bruit de l'image, basée sur la propriété multiplicative, et à en dériver l'algorithme de filtrage.

Par exemple, le filtre de Frost [JAQ-97], s'appuie sur la minimisation de l'espérance de l'erreur quadratique entre le signal réel et le signal reconstruit. La réponse impulsionnelle du filtre dans ce cas est de la forme (Fig. II.17) :

$$h(i, j) = K e^{-\alpha \sqrt{i^2 + j^2}} \quad (\text{II.48})$$

où K est une constante de normalisation et α est définie par :

$$\alpha = k \frac{\sigma_y(i, j)}{\bar{y}(i, j)} \quad (\text{II.49})$$

où $\sigma_y(i, j)$ et $\bar{y}(i, j)$ représentent respectivement l'écart type et la moyenne locales du signal et k est une constante exprimant le degré de filtrage.

Un autre exemple de filtres adaptatifs est celui de Lee. Son principe est basé sur la minimisation de l'erreur quadratique entre le signal réel et une approximation linéaire de ce signal. On obtient alors l'algorithme de filtrage suivant [JAQ-97]:

$$\hat{x}(i, j) = \bar{y}(i, j) + k(y(i, j) - \bar{y}(i, j)) \quad (\text{II.50})$$

où $\hat{x}(i, j)$ est le pixel filtré, $y(i, j)$ est le pixel réel et k est définie par :

$$k = \frac{\sigma_b^2(i, j)}{\bar{y}^2(i, j)\sigma_b^2 + \sigma_y^2(i, j)} \quad (\text{II.51})$$

Où σ_b est l'écart type du bruit.

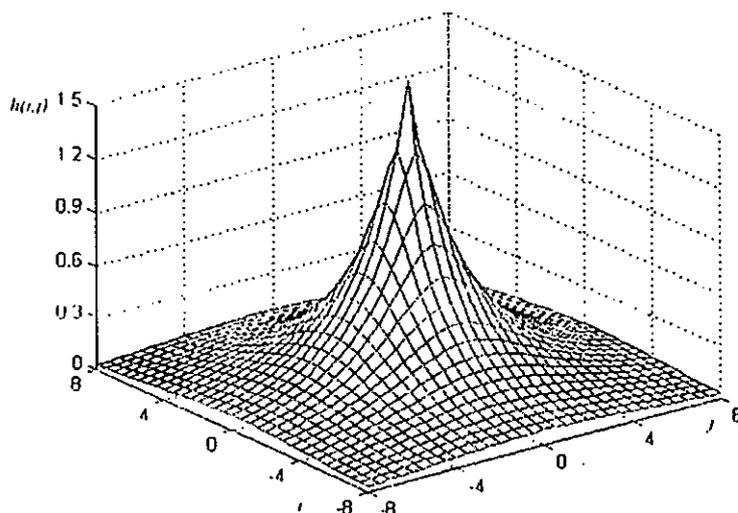


Fig. II.17 Réponse impulsionnelle du filtre de Frost.

5.2.3. Mise en œuvre et résultats

Dans cette partie nous avons effectué des tests en appliquant les filtres heuristiques et adaptatifs sur l'image de Laghouat de taille 200x200. L'efficacité du filtrage peut être mesurée par la réduction de la variance ou l'écart type du bruit, et la conservation de la radiométrie moyenne. La comparaison entre les différents filtres est donc faite selon ces deux critères. On peut également, comparer les performances de ces filtres en se basant sur l'index du speckle donné par:

$$I_S = \frac{1}{(M-2)(N-2)} \sum_{i=1}^M \sum_{j=1}^N \frac{\sigma(i,j)}{\mu(i,j)} \quad (II.52)$$

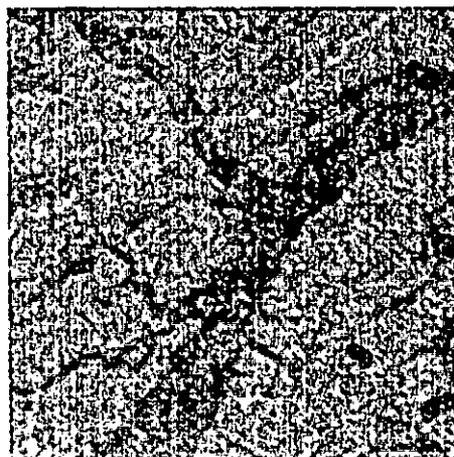
avec $\sigma(i,j)$ et $\mu(i,j)$ sont l'écart type et la moyenne locales respectivement. Ces trois paramètres sont calculés sur l'image originale et l'image filtrée voir tableau II.1. ces résultats montrent que le filtre de Frost donne les meilleurs résultats.

Image réelle	Image originale	Filtre moyen	Filtre médian	Filtre Nagao	Filtre de Frost	Filtre de Lee
Moyenne de l'image	87.2395	86.4516	85.1852	81.9077	86.2948	86.3587
Ecart type de l'image	29.0567	21.7981	20.5918	20.4692	19.7026	20.8222
Index du speckle	0.2013	0.0802	0.0643	0.0656	0.0503	0.0674

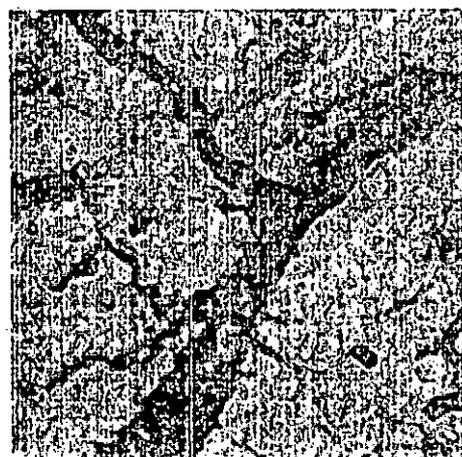
Tableau II.1. Résultats de filtrage.



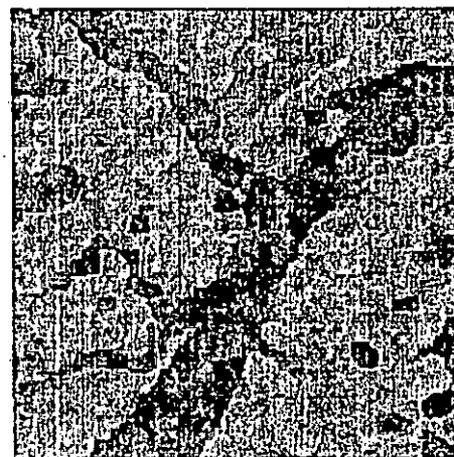
Image réelle



Filtre moyen



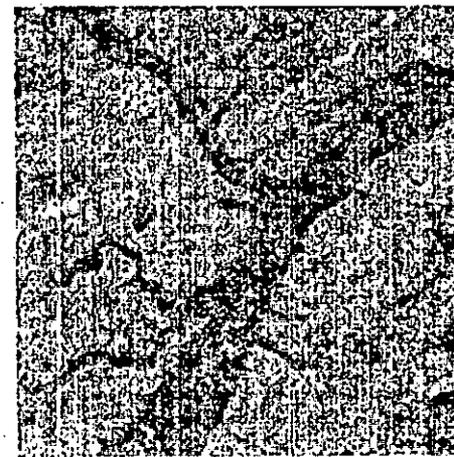
Filtre médian



Filtre Nagao



Filtre de Frost



Filtre de Lee

Fig. II.18 Résultats du filtrage heuristique et adaptatif (image réelle)

CONCLUSION

Le système radar imageur est un apport supplémentaire d'investigation à de nombreux domaines tels que la géologie, la géographie, l'évolution des terres (côtes, mouvement de terrains ...), l'aménagement et la gestion du territoire, la cartographie ... etc.

Afin d'exploiter et d'interpréter correctement les images SAR il est nécessaire de bien comprendre leur processus de formation, d'enregistrer ainsi que leurs types de distorsion comme cela a été présenté dans ce chapitre.

Une fois capables de « lire » une image radar, on peut en tirer l'information désirée. Parmi les applications du traitement des images SAR. On peut citer :

- Le Filtrage ou restauration (pré traitement des images)
- La Corrélation
- La Détection des structures (exemple : linéaire, réseau routier,...etc.)
- La Génération de modèle numérique de terrain MNT (Intérométrie radar, radardiométrie, radargrammétrie)

Ce travail se situe au niveau de la segmentation des images SAR en régions classées selon leurs caractéristiques d'homogénéité au sens de la rétrodiffusion avant d'interpréter et de décider. La reconstruction 3-D de l'image implique l'observation d'autres caractéristiques telles que les zones d'ombre ou/et d'inversion .

CHAPITRE III

CHAMPS ALEATOIRES

DE MARKOV

INTRODUCTION

La méconnaissance des lois exactes qui régissent tout phénomène ou processus étudié lui attribue un caractère aléatoire dont les grandeurs statistiques sont le seul moyen possible pour son analyse et son interprétation. En pratique, on ne dispose que d'un nombre limité des données. Ces données sont traitées de façons à extraire les caractéristiques du processus, surtout celles qui sont informatives pour les applications en questions. L'étude du processus est souvent réalisée à l'aide des modèles mathématiques représentés par un nombre limité de paramètres qui tentent d'approximer le processus générateur de données. L'utilisation de l'information a priori sur les données permet la sélection d'un modèle adéquat. Parmi les modèles récents utilisés en traitement d'images on trouve ceux qui sont fondés sur les champs aléatoires de Markov. Ils ont été introduits avec succès dans beaucoup de problèmes fondamentaux d'analyse d'images et vision par ordinateur tel que la restauration d'images [GEM-84], détection de contours [BLA-87], segmentation d'images [DER-87] [DER-88], classification multisource [SOL-96]. La théorie des champs Markoviens a été inspirée par la mécanique statistique (modèle Ising). Dans le traitement d'images, nous utilisons les mêmes termes : énergie, potentiel, température..., La démarche mathématique utilisée est probabiliste: les entités d'intérêt, contours, textures, régions ou d'autres attributs, dans une tâche donnée sont décrites par des modèles statistiques (MRF) et la théorie de l'estimation du Bayes est utilisée pour extraire l'information pertinente des images observées.

En définissant des modèles statistiques globaux, la théorie du MRF mène à une amélioration considérable par rapport aux méthodes locales classiques. Les MRF définissent une structure efficace et puissante pour spécifier des interactions non-linéaires

entre des attributs de même ou différente nature. Ils servent à combiner et à organiser l'information spatiale et temporelle en introduisant des connaissances génériques sur les attributs à estimer.

Dans ce chapitre, on discute les principaux fondements des champs aléatoires de Markov et leur lien avec le modèle de Gibbs. On s'intéresse aussi à la théorie de la décision au sens Bayésien qui est la base de l'estimation du Maximum a posteriori (MAP) largement utilisée dans l'étiquetage d'images. En outre, on explore le MRF pour la génération des images synthétiques par l'utilisation de l'échantillonneur de Gibbs.

1. JEUX DIFFERENTIELS ET DECISION

La décision en théorie des jeux différentiels, comme dans le cas de deux joueurs à somme zéro est fondée sur le triplet (\mathcal{G}, a, L) et une règle de décision $d(x)$ où :

- (i). θ : L'ensemble des états possibles.
- (ii). A : L'ensemble des actions possibles.
- (iii). $L(\mathcal{G}, a)$: Une fonction de perte définie sur $\theta \times A$.

Où θ, A représentent les espaces de toutes les configurations.

La valeur moyenne de $L(\mathcal{G}, d(X))$, quand \mathcal{G} est l'état vrai, est appelée la fonction de risque :

$$R(\mathcal{G}, d) = E\{L(\mathcal{G}, d(X))\} = \int L(\mathcal{G}, d(X)) dP(X/\mathcal{G}). \quad (\text{III.1})$$

Définition 1 : La fonction $d(x): X \rightarrow A$ est une règle de décision si la fonction de risque est finie pour tous les $\mathcal{G} \in \theta$.

Après les notations générales, nous intéressons à la décision Bayésienne.

Définition 2 : Le risque de Bayes relativement à la règle de décision δ et à la distribution P est donnée par

$$r(P, \delta) = E\{R(Y, \delta)\} \quad (\text{III.2})$$

où Y est une variable aléatoire sur θ avec une distribution de probabilité P .

Définition 3 : Etant donné une distribution a priori P et δ_0 est une règle de décision Bayésienne par rapport à P si

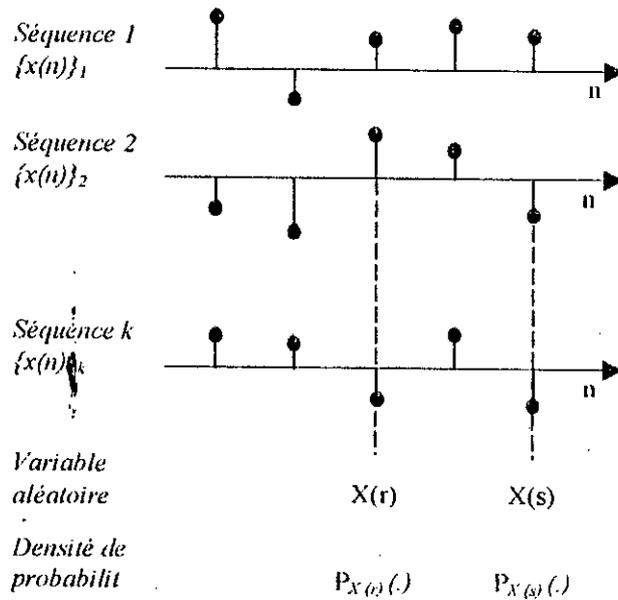
$$r(P, \delta_0) = \min_{\delta} (r(P, \delta)) \quad (\text{III.3})$$

la valeur $r(P, \delta_0)$ est appelée le risque minimal de Bayes.

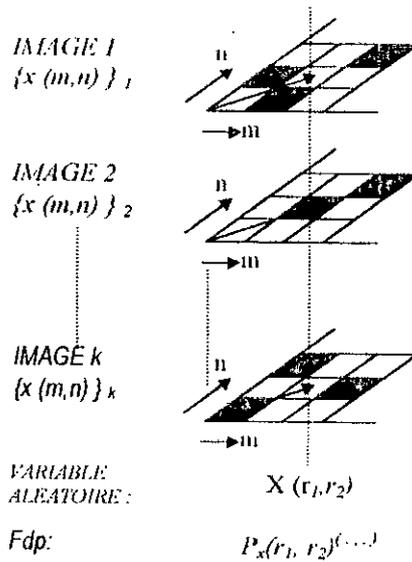
2. PROCESSUS ALEATOIRE

Le processus aléatoire est le nom attribué à tout phénomène évoluant de manière imparfaitement imprévisible, en fonction d'un paramètre physique (généralement le temps ou les coordonnées d'espaces) suivant les lois de probabilités. L'analyse d'un processus aléatoire se fait souvent par le biais de plusieurs séries indépendantes d'observations (ou épreuves) enregistrées à partir de celui-ci et appelées réalisations. Supposant que $\{x(n)\}$, $n = \pm 1, \pm 2, \dots$ est une réalisation, prélevée arbitrairement d'un processus aléatoire. A un instant donné n , la valeur $x(n)$ de la séquence $\{x(n)\}$, est une valeur particulière d'une variable aléatoire $X(n)$ voir la figure III.1. l'ensemble ordonné de $\{X(n)\}$ est un processus aléatoire dont le comportement est décrit par des densités de probabilités conjointes.

L'extension au cas bidimensionnel, pour le cas des images fixes, (2-D) est illustrée à la figure III.1. Le niveau de gris de chaque pixel aux coordonnées (m,n) est dénoté par $x(m,n)$, qui est une réalisation de la variable aléatoire $X(m,n)$. Ici, l'ensemble des variables $\{X(m,n)\}$ est appelé un champ aléatoire.



(a)



(b)

Fig III.1. (a) Processus aléatoire. (b) Champ aléatoire.

3. CHAÎNE DE MARKOV

3.1 Processus markovien

un processus stochastique $X(t)$ est un processus markovien si pour chaque n pour chaque $1 < t_2 < \dots < t_n$, on a

$$P\{X(t_n) \leq x_n | X(t_{n-1}), \dots, X(t_1)\} = P\{X(t_n) \leq x_n | X(t_{n-1}), i = 1, \dots, m\} \quad (\text{III.4})$$

m est l'ordre du processus.

3.2 Chaîne de Markov

Soit $\{X_i\} = X_1, X_2, \dots, X_n, \dots$ une séquence de variables aléatoires avec les valeurs possibles a_1, \dots, a_N . Si la propriété markovienne est satisfaite :

$$P\{X_n = a_n | X_{n-1} = a_{i_{n-1}}, \dots, X_1 = a_{i_1}\} = P\{X_n = a_n | X_{n-1} = a_{i_{n-1}}\} \quad (\text{III.5})$$

alors $\{X_i\}$ est une chaîne de Markov avec les probabilités limites :

$$p_i(n) = P(X_n = a_i) \quad (\text{III.6})$$

et probabilités conditionnelles ou de transition :

$$p_{ij}(n, s) = P\{X_n = a_i | X_s = a_j\} \quad (\text{III.7})$$

Une chaîne de Markov est dite homogène si les probabilités conditionnelles $P_{ij}(n, n+1)$ ne dépendent pas de n et dite stationnaire si les probabilités limites ne dépendent pas de n , c'est à dire :

$$\forall n: p_k^n = p_k \quad (\text{III.8})$$

4. CHAMP ALEATOIRE DE MARKOV

Dans cette partie on va donner une définition pour le champ aléatoire de Markov MRF défini sur une maille de $N1 \times N2$ sites $l = \{(i, j), 1 \leq i \leq N1, 1 \leq j \leq N2\}$. On suppose que chaque

variable aléatoire $X(i,j)$ est définie sur l'ensemble des étiquettes $A=\{0,1,\dots,G-1\}$ où G est le nombre de niveaux de gris possible dans une image, soit $G=2$ pour les images binaires et $G=256$ pour les image 8-bits. Soit Ω l'ensemble de toutes les configurations possibles :

$$\Omega = \{\omega = (x(i,j) : (i,j) \in L) ; x(i,j) \in A\} ; \tag{III.9}$$

(i.e. $\text{card}(\Omega) = G^{N_1 \cdot N_2}$).

4.1. Système de voisinage

Une collection de sous-ensembles de L décrite par $\eta = \{\eta_{ij}, (i,j) \in L, \eta_{ij} \subset L\}$ est un système de voisinage si et seulement si η_{ij} , l'ensemble de pixels voisins au pixel (i,j) , est tel que

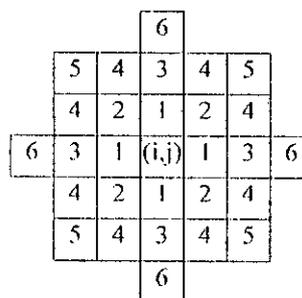
1. $(i,j) \notin \eta_{ij}$, et
2. si $(k,l) \in \eta_{ij}$ alors $(i,j) \in \eta_{kl}$ pour tout $(i,j) \in L$.

Les séquences ordonnées, des systèmes de voisinages qui sont souvent utilisés dans la modélisation d'images sont $\eta_1, \eta_2, \eta_3, \dots$: $\eta_1 = \{\eta_{ij}^1\}$ est le système de voisinage de premier ordre, et pour lequel η_{ij}^1 admet quatre voisins les plus proches du pixel (i,j) . $\eta_2 = \{\eta_{ij}^2\}$ est le système de voisinage de second ordre, tel que η_{ij}^2 admet huit pixels voisins de (i,j) . Les structures de voisinage de η_1 et η_2 , ainsi que de η_3, η_4 et η_5 sont montrées (Fig III.2).

D'une manière générale un système de voisinage d'ordre m , $\eta_m = \{\eta_{ij}^m\}$ est tel que :

$$\eta_{ij}^m = \{(k,l) : (k,l) \in L \text{ et } (i-k)^2 + (j-l)^2 \leq m\} \tag{III.10}$$

On peut maintenant définir un MRF par rapport au système de voisinage défini sur la maille L



$$\eta^m = \{\eta_{ij}^m\}$$

$$\eta_{ij}^m = \{k : k \leq m\}$$

Fig III.2. Les structures des systèmes de voisinages η_m .

4.2. Champ aléatoire de Markov

La propriété fondamentale des champs de Markov, appliquée au traitement d'images, est que l'on suppose que la probabilité conditionnelle de la valeur estimée d'un pixel donnée, sachant l'état de tous les autres pixels, est égale à la probabilité conditionnellement aux états des sites voisins.

Soit η un système de voisinage défini sur la maille L . Un champ aléatoire $X = \{X_{ij}\}$ défini sur la maille L est un champ aléatoire de Markov par rapport au système de voisinage η si et seulement si sa densité de probabilité jointe satisfait les trois conditions suivantes :

1) La condition de positivité :

$$P(X(\omega) = x) > 0 \text{ pour tout } \omega \in \Omega. \quad (\text{III.11})$$

2) La propriété de Markov :

$$P(X_{ij} = x_{ij} / X_{kl} = x_{kl}, (k,l) \in L - \{(i,j)\}) = P(X_{ij} = x_{ij} / X_{kl} = x_{kl}, (k,l) \in \eta_{ij}) \quad (\text{III.12})$$

3) La condition d'homogénéité : $P(X_{ij} = x_{ij} / X_{kl} = x_{kl}, (k,l) \in \eta_{ij})$

est la même pour tous les sites.

Puisque la maille utilisée est finie, les voisins des pixels aux frontières sont nécessairement très petits à moins qu'une structure périodique soit supposée. Cela signifie que la première ligne de l'image est connectée avec la dernière ligne et la première colonne est connectée avec la dernière colonne. Selon la définition précédente, un MRF est caractérisé par une distribution conditionnelle appelée la caractéristique locale du champ aléatoire. Précisément, ces difficultés sont des problèmes consistants concernant la distribution jointe et la disponibilité de cette fonction. Ces difficultés sont levées en caractérisant MRF par la distribution de Gibbs GD.

5. LE CHAMP ALEATOIRE DE GIBBS (GRF)

Pour définir un GRF, premièrement il est nécessaire de définir les cliques associées avec le couple (L, η) .

5.1. Cliques

Une clique du couple (L, η) notée par c , est un sous-ensemble de L tel que

1. c consiste en un pixel unique, ou

2. Pour $(i,j) \neq (k,l), (i,j) \in c$ est $(k,l) \in c$ implique que $(i,j) \in \eta_{kl}$.

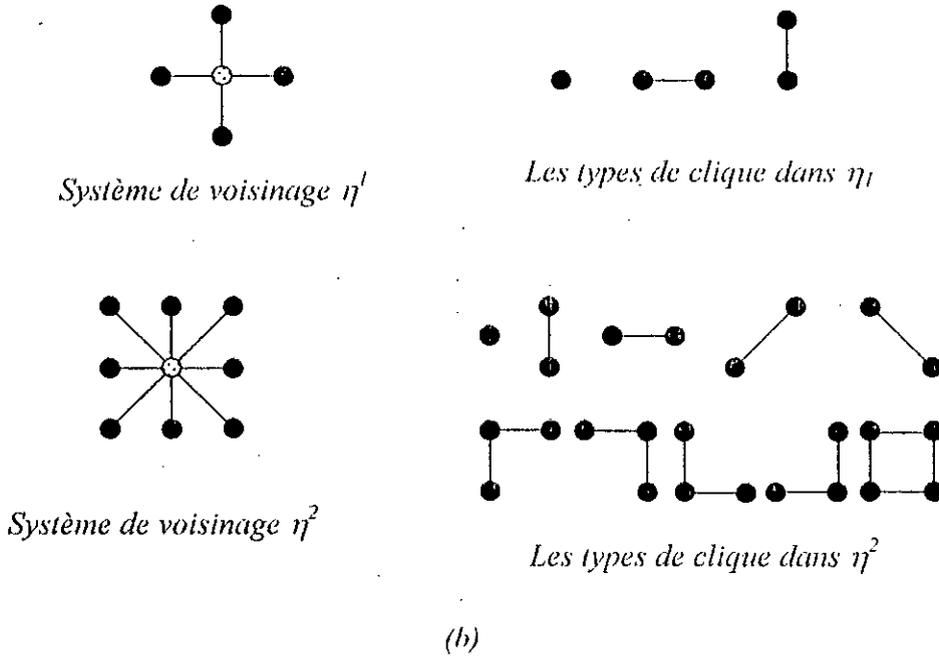


Figure III.3. systèmes de voisinage premier ordre et second ordre et leurs types de cliques.

Cela signifie que c est un singleton ou un sous-ensemble de L dont chaque pair sont voisins au sens de η .

La collection de toutes les cliques de (L, η) est notée par $C=C(L, \eta)$.

5.2. Distribution de Gibbs

Soit η un système de voisinage défini sur une maille finie L . Un champ aléatoire $X=\{X_{ij}\}$ défini sur L a une distribution de Gibbs par rapport à η si et seulement si sa distribution jointe est de la forme :

$$P(X(\omega) = x) = \frac{\exp(-U(x))}{Z} \tag{III.13}$$

Où $U(x)$ est appelée fonction d'énergie, elle est définie par :

$$U(x) = \sum_{c \in C} V_c(x) \quad (\text{III.14})$$

Les fonctions $V_c(x)$ sont appelées des fonctions potentielles et ne dépendent que des valeurs de $x(i,j)$ et non pas de leurs emplacements (i,j) (condition d'homogénéité).

Le paramètre Z est appelé fonction de répartition, c'est en fait une constante de normalisation de la probabilité jointe $P(X(\omega)=x)$ (i.e. on doit avoir $\sum_{\omega \in \Omega} [P(X(\omega)=x)] = 1$);

donc :

$$Z = \sum_{\omega \in \Omega} \exp(-U(x)) \quad (\text{III.16})$$

Les origines de la distribution de Gibbs reviennent à la physique et les études statistiques en mécanique. Ising a utilisé une distribution spéciale de Gibbs, connue comme le modèle d'Ising, pour décrire les propriétés magnétiques et ferromagnétiques des matériaux. L'introduction de ce modèle dans le contexte de modélisation et traitement d'image est due au théorème de Hammersley Clifford Ce résultat prouvé en 1970 par plusieurs chercheurs, établi la relation entre le champ MRF et le champ GRF

Théorème : Soit η un système de voisinage sur une maille finie L . Un champ aléatoire X est un champ MRF par rapport à η si et seulement si sa distribution jointe est une distribution de Gibbs avec les cliques associées à η .

5.3. Probabilités conditionnelles

Une interprétation intuitive de la propriété de Markov (III.12) est que l'information contextuelle fournie par $L - \{(i,j)\}$ est la même que l'information statistique fournie par les voisins de (i,j) . Le champ aléatoire de Markov exprime les interactions statistiques globales en termes de combinaison des interactions locales ou les probabilités conditionnelles. Dans cette partie on cherche l'expression de ces probabilités en se basant sur la distribution de Gibbs. Soit $x \in \Omega$, une configuration arbitraire et soit (i,j) un pixel de la maille L donc :

$$\begin{aligned} P(X_{ij} = x_{ij} / X_{kl} = x_{kl}, (k,l) \in L - \{(i,j)\}) \\ = \frac{P(X(\omega) = x)}{P(X_{kl} = x_{kl}, (k,l) \in L - \{(i,j)\})} \end{aligned} \quad (\text{III.17})$$

$$= \frac{Z^{-1} \exp(-U(x))}{\sum_{k=0}^{G-1} P(X_{ij} = k, X_{kl} = x_{kl}, (k, l) \in L - \{(i, j)\})} \quad (\text{III.18})$$

$$= \frac{\exp(-\sum_{c \in C} V_c(x))}{\sum_{k=0}^{G-1} \exp(-\sum_{c \in C} V_c(x^k))} \quad (\text{III.19})$$

où x_k désigne la configuration x pour laquelle $x(i,j)=k$. Puisque, pour toute clique c ne contenant pas (i,j) on a $V_c(x)=V_c(x_k)$, alors (III.19) devient :

$$P(X_{ij} = x_{ij} / X_{kl} = x_{kl}, (k, l) \in L - \{(i, j)\}) = \frac{\exp(-\sum_{c \in C: (i,j) \notin c} V_c(x))}{\sum_{k=0}^{G-1} \exp(-\sum_{c \in C: (i,j) \notin c} V_c(x^k))} \quad (\text{III.20})$$

Remarquons que les sommes définissant ces probabilités conditionnelles dans l'équation (III.20) contiennent un très petit nombre de termes (ce nombre est lié à l'ordre du système de voisinage) et donc que leur calcul est relativement rapide. En effet, les algorithmes de relaxation stochastiques et déterministes (voir chapitre III) utilisé pour la simulation du modèle de Markov ne nécessitent qu'un pixel et ses voisins. Ainsi, la mise à jours des pixels demeure locale.

6. FONCTION D'ENERGIE ET FONCTIONS POTENTIELLES

Afin de spécifier la distribution, nous avons besoins de définir les fonctions potentielles $V_c(x)$. Pour cela, nous avons fait une analogie avec la physique statistique où les pixels de l'image sont considérés comme des atomes arrangés sur un réseau régulier de sites, et pouvant se trouver dans plusieurs états énergétiques (ou niveaux de gris). L'état de chaque pixel ne dépend que de son interaction avec ses voisins. Ainsi, les fonctions $V_c(x)$ représentent les contributions à la fonctions d'énergie $U(x)$ de l'énergie des cliques singletons, l'énergie d'interactions entre les paires de pixels (cliques doubletons), et ainsi de suite. Les modèles les plus utilisés pour la représentation des images sont :

6.1. Modèle d'Ising

Ce modèle est inventé par Ising en 1925, il est appliqué sur le système de voisinage de premier ordre (voir figure 1) pour lequel la fonction d'énergie est la contribution des potentiels des cliques formées par un seul pixel et les potentiels des cliques formées par les voisins verticaux ou horizontaux. Dans ce cas la fonction d'énergie $U(x)$ est exprimée par :

$$U(x) = \alpha \sum_{(i,j)} x(i,j) + \beta \left(\sum_{(i,j)} [x(i,j)x(i+1,j)] + \sum_{(i,j)} [x(i,j)x(i,j+1)] \right) \quad (\text{III.21})$$

où le deuxième terme de la somme correspond aux potentiels de cliques verticaux et le dernier correspond aux potentiels de cliques horizontaux, α et β sont des paramètres qui caractérisent le regroupement et l'orientation des pixels.

6.2. Modèle auto-binomial

Ce modèle a été appliqué par Cross et Jain [CRO-83] pour la modélisation des images texturées.

Pour le système de second ordre (figure III.3.(b)), la fonction d'énergie est donnée par :

$$U(x) = \sum_{(i,j)} \left(\alpha x(i,j) - \ln \left[C_{x(i,j)}^{(G-1)} \right] \right) + \left(\sum_{(i,j)} \sum_{k=-1}^1 \sum_{l=0}^1 \beta(k,l) x(i,j) x(i-k, j-l) \right)_{(k,l) \neq (0,0)} \quad (\text{III.22})$$

où C_b^a est défini par :

$$C_b^a = \frac{b!}{a!(b-a)!} \quad (\text{III.23})$$

Ce modèle n'utilise que les cliques constituées par deux pixels. Le paramètre $\beta(1,0)$ agit sur la dépendance spatiale dans la direction horizontale, $\beta(0,1)$ influence sur la dépendance spatiale dans la direction verticale, $\beta(-1,1)$ et $\beta(1,1)$ influencent fortement sur l'apparence des lignes diagonales dans l'image.

L'expression de la fonction d'énergie pour les systèmes de voisinages d'ordres supérieurs peut être trouvée dans [CRO-83].

6.3. Modèle Multi-Level Logistique

En effet, c'est le modèle utilisé dans notre travail. Le système de voisinage utilisé est celui du second ordre η_2 . L'extension aux systèmes de voisinages d'ordre élevé ou inférieur est évidente. Ce modèle est utilisé par Derin et Elliot pour la segmentation des images bruitées et texturées [DER-87]. La fonction d'énergie est comme suit: Un paramètre est assigné à chaque type de clique, à l'exception des cliques constituées par un seul pixel.

$$\begin{aligned}
 & [^{**}, \beta_1], [^*, \beta_2], [^{**}, \beta_3], [^*, \beta_4] \\
 & [^{**}, \gamma_1], [^*, \gamma_2], [^{**}, \gamma_3], [^*, \gamma_4], [^{**}, \xi_1]
 \end{aligned}
 \tag{III.24}$$

Les potentiels de cliques associés à chacune de ces cliques sont définis par :

$$V_c(x) = \begin{cases} -\theta & \text{si tout les } x_{ij} \text{ dans } c \text{ sont égaux.} \\ \theta & \text{dans le cas contraire.} \end{cases}
 \tag{III.25}$$

où θ est un paramètre spécifié pour le type de clique c .

Pour les cliques singletons le potentiel est défini par :

$$V_c(x) = \alpha_k \text{ pour } x_{ij} = k ; k \in \Lambda.
 \tag{III.26}$$

Les α_k sont des paramètres utilisés pour contrôler le pourcentage de pixels dans chaque type de région. Par contre les autres paramètres sont utilisés pour contrôler la taille et la direction de regroupement des pixels dans l'image.

7. MODELE HIERARCHIQUE DES IMAGES

Le modèle hiérarchique est celui utilisé dans la segmentation des images. Il se base sur la distribution de Gibbs et le modèle de bruit ou textures associés à cette image.

On décrira une image numérique $y = \{y_{ij}\}$ comme une matrice $N1 \times N2$ d'observations d'une scène. On supposera aussi que cette matrice y est une réalisation spécifique d'un champ aléatoire $Y = \{Y_{ij}\}$. La maille L associée à ce champ est la collection de $N1 \times N2$ emplacements du pixel.

L'objectif est de construire le champ aléatoire Y afin qu'il caractérise l'information contenue dans l'image. Les modèles hiérarchiques proposés pour tous les types d'images (optiques et radar, ...) ont un niveau haut identique (processus de formation de régions), mais ils ont un niveau bas différent.

Le champ aléatoire Y est défini en termes d'un champ aléatoire X (scène à analyser). La scène X est un champ aléatoire discret où X_{ij} prend des valeurs dans Λ pour chaque $(i,j) \in L$. $X_{ij}(\omega) = x_{ij} = k$ dénote le fait que le pixel (i,j) dans la réalisation x appartient au type k . Donc une réalisation $x = X(\omega)$ est simplement une partition du maille L en G types région. Chaque type région peut se produire en plus qu'un emplacement dans la maille. Par exemple, une image de télédétection peut consister de nombreuses entités d'eau (lacs, mer, rivières,...) , sont tous caractérisées par un seul type région. La scène X est supposée toujours d'être un champ aléatoire de Gibbs. Ce dernier représente le processus de formation des régions qui est le processus du niveau haut dans le modèle hiérarchique.

Au niveau bas du modèle hiérarchique, on suppose qu'il y a G textures, T_k ; $k \in \Lambda$ chacun est un champ aléatoire discret défini sur la maille L et prenant valeurs dans $G_k = \{g_1, g_2, \dots, g_{qk}\}$, où qk dénote le nombre des niveaux de gris dans la texture T_k et $\{g_{ki}\}_{i=1}^{qk}$ sont les niveaux gris possibles dans T_k . La distribution de T_k dépend de type d'image, elle peut être Gaussienne, Gamma ou une même une distribution de Gibbs. Pour le cas des images SAR, T_k suit la loi Gamma ou la loi de distribution k . On suppose aussi que le processus de région X et les textures T_k soit des champs mutuellement indépendants.

L'image Y est définie maintenant formellement par :

$$Y_{ij}() = T_{ij}^k \text{ si } X_{ij}(); k \in \Lambda \text{ et pour tout } (i,j) \in L. \quad (\text{III.27})$$

8. GENERATION DES IMAGES SYNTHETIQUES

L'information contenue dans une image réelle ne représente pas le phénomène observé. En effet, cette information est affectée fortement par le bruit, constituant un phénomène indésirable surchargeant l'image. Dans le cas d'une image simulée l'information utile représentant une image non bruitée (idéale) est créée indépendamment au bruit. Par conséquent il est plus approprié d'évaluer le comportement d'un traitement quelconque sur des images simulées que sur des images réelles car il est difficile de dire sur certains détails ont été préservés après traitement d'une image réelle. Par contre dans le cas de la simulation connaissant l'image idéale, il suffit de comparer celle-ci avec l'image traitée, d'où l'intérêt de génération des images synthétiques.

L'utilisation des méthodes classiques, refus-acceptation et la décomposition en probabilité conditionnelle, pour générer une réalisation d'un champ aléatoire de Gibbs avec des paramètres donnés nécessite le calcul de la fonction de répartition Z après celui des sommes de $G^{N1.N2}$ (III.16), qui est pratiquement impossible même pour des images binaires et de petite taille (64x64). Pour palier à ce problème, on a recours de mises en œuvre des algorithmes de type Monte Carlo, simulant une chaîne de Markov à temps discret, dont les états constituent l'espace Ω de toutes les configurations possibles. Dans ce travail nous avons utilisé l'algorithme appelé échantillonneur de Gibbs, introduit par S. Geman et D. Geman [GEM-84].

L'échantillonneur de Gibbs

L'algorithme se décompose de la manière suivante :

1. Fixer les paramètres de la distribution de Gibbs.
2. $n=0$;
3. Tirer une configuration initiale $x^{(n)}$, en affectant à chaque site (i,j) de L une couleur aléatoirement de A .
4. Balayer l'ensemble de sites L (ligne par ligne, ou dans n'importe quel ordre). En chaque site (i,j) , calculer l'ensemble des probabilités conditionnelles $P(X_{ij} = x_{ij} / X_{kl} = x_{kl}, (k,l) \in \eta_{ij}^{(n)})$ donner par (III.20), où $\eta_{ij}^{(n)}$ est le voisinage courant du pixel (i,j) . Ensuite effectuer un tirage aléatoire suivant la loi précédente pour obtenir $x_{ij}^{(n+1)}$.
5. Répéter l'étape (3) jusqu'à ce que $n=N_{iter}$.

Les densités conditionnelles dans l'étape 4 peuvent être calculées facilement puisqu'elles nécessitent que l'utilisation des voisinages locaux de chaque site.

Si cette distribution est discrète, il est habituellement très commode d'utiliser la méthode de fonction inverse pour effectuer le tirage dans l'étape 3.

La convergence de l'algorithme vers la distribution désirée est assurée par le théorème de Hammersley-Clifford. La valeur de N_{iter} , est fixé par la stabilité des pixels qui changent ou par la stabilité des paramètres estimés (voir chapitre V). Dans la figure III.4, on présente quatre réalisations représentant le processus de région X de deux, trois et quatre niveaux de gris. La figure III.5 représente sont quatre réalisations de processus Y des textures (tous ont quatre niveaux de gris) ayant une distribution de Gibbs.

Pour cette application nous avons utilisé un système de second ordre, générant trois types de cliques, parmi lesquels nous n'avons retenu que les cliques d'ordre deux (deux pixels voisins). Nous avons choisi pour la fonction de potentiel $V_c(x)$ le Modèle MLL (Multilevel-logistic). Ainsi, les seuls paramètres utilisés sont β_1 , β_2 , β_3 et β_4 .

9. CONCLUSION

Nous avons présenté dans ce chapitre les notions de base du champ de Markov : systèmes de voisinage, cliques, fonction potentiel et fonction d'énergie. Nous avons donné aussi la relation d'équivalence qui existe entre le champ de Markov et le champ de Gibbs en rapport avec le théorème Hammersley Clifford. Cette relation permet d'exprimer la propriété de Markov formellement, ce qui facilite l'utilisation des MRF. Nous avons vu que l'avantage principal du MRF est qu'il modélise la distribution jointe de l'image en termes de distributions conditionnelles locales, d'où l'efficacité des calculs. Notre application dans ce chapitre, était la génération des réalisations des champs de Gibbs par l'utilisation de l'échantillonneur de Gibbs. Les résultats obtenus montrent l'influence des paramètres du modèle sur le type d'images. Afin de bénéficier des avantages des Modèles de Markov, nous les utiliserons par la suite dans le problème de la segmentation d'images.

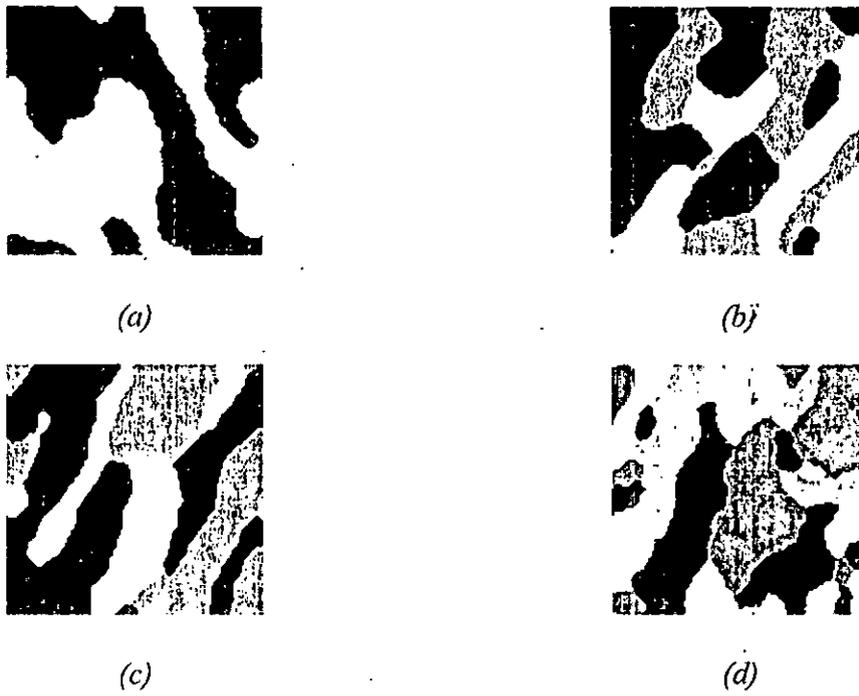


Figure III.4. Image régions (a) binaire avec $\beta_i=0.9$. (b) trois régions avec $\beta_i=1$. (c) trois régions avec $\beta_i=2$. (d) quatre régions avec $\beta_i=0.7$.

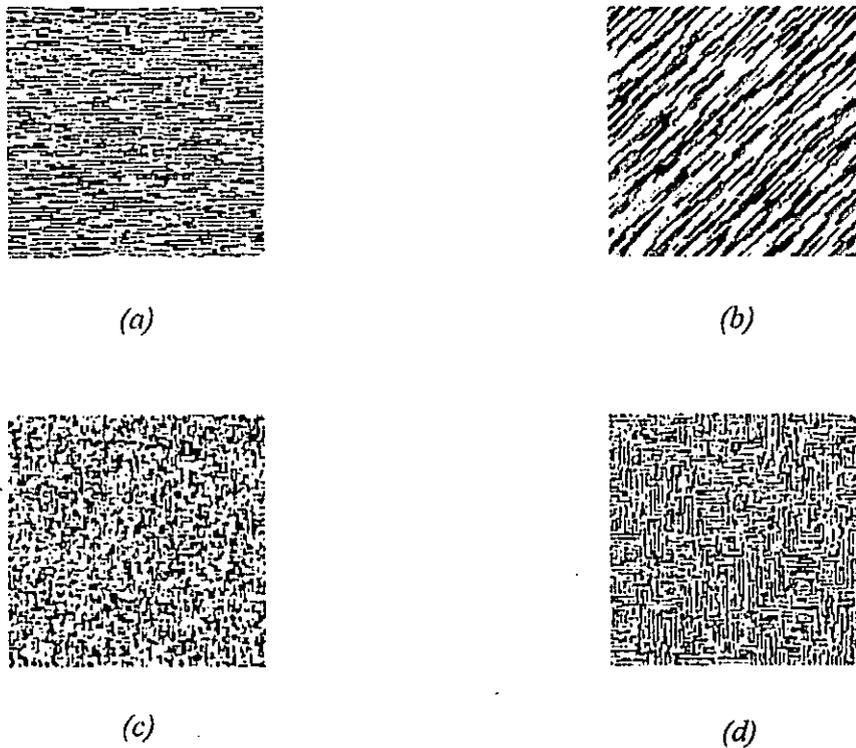


Fig III.5. Image texturée (a) avec $\beta_1=1.0, \beta_2=\beta_3=\beta_4=-1.0$. (b) avec $\beta_1=\beta_2=\beta_3=1.0, \beta_4=-1.0$. (c) avec $\beta_1=\beta_2=1.0, \beta_3=\beta_4=-1.0$. (d) avec $\beta_1=\beta_2=1.0, \beta_3=\beta_4=-0.5$.

CHAPITRE IV

SEGMENTATION SUPERVISEE

DES IMAGES SAR

INTRODUCTION

Une tâche importante en traitement d'images est de segmenter l'image donnée en des régions significatives ayant certaines propriétés communes et d'étiqueter les régions individuelles. Une région dans l'image SAR peut être caractérisée soit par le constant de réflectivité ou par sa texture. Les régions segmentées et étiquetées sont ensuite détectées et classifiées selon leurs propriétés comme champs agricoles, agglomérations urbaines, zones humides, chemins routiers, etc. Il existe deux approches majeures pour la segmentation d'images à savoir l'approche contours et l'approche régions. C'est cette dernière approche qui est utilisée dans notre travail. Les méthodes approche contours, soient celles qui s'appuient le calcul du maximum local de l'amplitude du gradient et celles qui se basent sur le calcul des passages par zéro de la deuxième dérivée, détectent en premier les discontinuités locales et en second procèdent à la fermeture des contours pour délimiter les constituants de l'image. Par ailleurs, les méthodes de segmentation approche région telle que la méthode de seuillage de l'histogramme et la méthode de croissance de régions [PRA-91][KUN-96][COQ-96], tentent à localiser les régions ayant des caractéristiques homogènes qui donneront par la suite l'image contours. L'utilisation des méthodes classiques des deux approches est confrontée par la présence de speckle et de texture dans l'image SAR, qui détectent des faux contours et de fausses régions [HSI-89].

Ces dernières années, l'utilisation des techniques de segmentation basées sur la modélisation statistique s'est élargie. Dans de telles techniques, une image est divisée en un ensemble de régions disjointes. Chaque région est associée avec un champ aléatoire (de Gauss, distribution K , exponentielle,...). Ceci permet d'intégrer toutes les informations a priori sur l'image. En plus, on attache à chaque pixel une étiquette caractérisant son appartenance à l'ensemble des classes. Le processus des étiquettes est généralement modélisé par un champ aléatoire de Markov. L'avantage de cette modélisation est d'incorporer la contrainte continuité spatiale des régions, ainsi le champ MRF peut être vu

comme régularisateur dans le sens où il aide à résoudre le problème mal posé de la segmentation. Ce problème revient à trouver l'image étiquetée invisible à partir de l'image donnée en se basant sur le modèle statistique choisi.

Dans notre approche de segmentation, nous avons utilisé l'estimateur Maximum a posteriori (MAP) pour résoudre le problème d'étiquetage. Malheureusement, une maximisation directe est impossible à cause de l'espace de configuration de la solution. Par exemple, pour une image binaire de taille 64x64 l'espace est de $2^{64 \times 64}$. de ce fait, nous avons proposé deux types d'algorithmes d'optimisation :

- Les algorithmes stochastiques qui convergent théoriquement vers le maximum global, mais qui ont l'inconvénient d'être très lourds.
- Les algorithmes déterministes qui convergent rapidement, mais vers les minima locaux qui dépendent de l'initialisation.

1. LE PROBLEME DE SEGMENTATION

Soit la maille $L = \{ (i,j), 1 \leq i \leq N1, 1 \leq j \leq N2 \}$, l'ensemble des sites (pixels de l'image) et $\Lambda = \{ 0, 1, \dots, G-1 \}$ l'ensemble des étiquettes que peut prendre chaque pixel. Chaque site peut prendre une étiquette de 0 à G-1. On suppose que l'image des observations $y = \{ y_{i,j}, (i,j) \in L \}$ est une réalisation d'un champ aléatoire Y. On définit un champ aléatoire X sur l'ensemble des étiquettes $X = \{ X_{i,j}, (i,j) \in L \}$ où $X_{i,j}$ chaque prend ses valeurs dans Λ . la segmentation de l'image consiste à partitionner l'image en un nombre de régions $\mathfrak{R}_n \subset L$ disjointes telle que :

$$L = \bigcup_n \mathfrak{R}_n \text{ et } \mathfrak{R}_m \cap \mathfrak{R}_n = \emptyset \text{ pour tout } m \neq n \quad (\text{IV.1})$$

et à attribuer à chaque pixel de l'image une étiquette dans Λ . Le but est que pour une réalisation d'une image specklée y donnée, on doit déterminer la réalisation des champs des étiquettes qui a donné naissance à y . La réalisation x est non mesurable et ne peut être trouvée directement à partir de y . Dans ce cas le problème se résume à trouver l'estimée $\hat{x} = \hat{X}(y)$ de la scène X, en se basant sur la réalisation y . Ayant formulé le modèle statistique, on adopte l'estimation de maximum a posteriori (MAP) comme un critère statistique. Ainsi, l'objectif maintenant est d'avoir un algorithme d'estimation, lequel fournira l'estimée \hat{x} qui maximise la distribution a posteriori $P(X=x/Y=y)$ pour y donnée. Dans la section suivante on donne un algorithme qui réalise cette tâche.

2. ALGORITHME DE SEGMENTATION MAP

Dans cette approche, la segmentation est considérée comme l'estimation du champ des étiquettes X(image segmentée) à partir d'une réalisation y du champ des observations, en maximisant la loi a posteriori $P(X=x/Y=y)$:

$$\hat{x} = \underset{x}{\operatorname{argmax}} P(X=x/Y=y) \quad (\text{IV.2})$$

Par l'utilisation du théorème de Bayes, on aura :

$$P(X = x / Y = y) = \frac{P(Y = y / X = x)P(X = x)}{P(Y = y)} \quad (\text{IV.3})$$

Comme $P(Y=y)$, la loi a priori, est fixe pour une réalisation donnée alors il est équivalent de maximiser le numérateur du membre droit de l'équation précédente, qui est la distribution jointe $P(X=x, Y=y)$ ou son logarithme :

$$E_{\text{glob}} = \operatorname{Log}(P(Y = y / X = x)) + \operatorname{Log}(P(X = x)) \quad (\text{IV.4})$$

où E_{glob} est appelée fonction d'énergie globale.

Il est à noter que la distribution à posteriori $P(X=x/Y=y)$ est aussi une distribution de Gibbs avec le même système de voisinage que la distribution a priori $P(X=x)$ [GEM-84], ainsi :

$$P(X = x / Y = y) = \frac{\exp(E_{glob})}{Z'} \quad (IV.5)$$

où Z' est une constante de normalisation. Cette remarque est très importante dans le sens où tous les algorithmes stochastiques (voir section 3) sont basés sur la construction d'une chaîne de Markov ayant pour distribution limite la loi de Gibbs.

Une maximisation brute est simplement hors de question à cause le nombre élevé de solutions possibles ($G^{N1.N2}$ configurations). Dans la littérature, ce problème a été résolu par la méthode d'optimisation comme la programmation dynamique [DER-87], les algorithmes de relaxation stochastique [GEM-84], les algorithmes de relaxation déterministe [BES-89] et dernièrement les algorithmes génétiques. Dans notre travail, on a choisi les méthodes de relaxation déterministe et aléatoire.

3. LE MODELE DE SEGMENTATION

Dans cette section on présente l'expression de la fonction d'énergie en se référant au modèle statistique des images SAR. Ceci est obtenu en définissant les lois de probabilité du champ des étiquette et du champ des observations.

La fonction d'énergie globale vu dans la section précédente est la somme de deux termes :

- $U_1(y/x) = \text{Log}(P(Y=y/X=x))$ le terme attache aux données et
- $U_2(x) = \text{Log}(P(X=x))$ le terme régularisateur.

En supposant que le processus X des étiquettes est un MRF, donc d'après le théorème de Hammerslay Clifford, il suit la loi de distribution de Gibbs (chapitre III). De ce fait on obtient :

$$U_2(x) = -\text{Log}(Z) - \sum_{(i,j) \in l} \sum_{c \in C: (i,j) \in c} V_c(x) \quad (IV.6)$$

où C est l'ensemble de toutes les cliques, Z et la fonction de répartition et $V_c(x)$ est le potentiel de clique c . Si on considère un système de voisinage d'ordre deux et on ne retient que les cliques pairs avec $\beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta$, alors $V_c(x)$ peut s'écrire

$$V_c(x) = \beta \sum_{(k,l) \in n_{i,j}} I(x_{i,j}, x_{k,l}) \quad (IV.7)$$

où $I(x_{i,j}, x_{k,l})$ est définit par :

$$p_i = \frac{\exp \frac{-E(x)}{kT}}{\sum_{j \in \Omega} \exp \frac{-E(x)}{kT}} \quad (\text{IV.16})$$

où Ω est l'espace de toutes les configurations et k est la constante de Boltzmann.

Dans cette expression, le facteur kT montre que lorsque la température est très élevée, tout les états sont à peu près équiprobables, c'est-à-dire un grand nombre de configurations sont accessibles. Au contraire quand la température est basse, les états à haute énergie deviennent peu probables par rapport à ceux de faible énergie.

Cette analogie nous conduit à utiliser l'expression suivante pour la fonction d'énergie :

$$E(x) = \frac{U1(y/x) + U2(x)}{T} \quad (\text{IV.17})$$

où nous avons pris $k=1$.

et l'algorithme de recuit simulé se présente sous la forme général suivante :

- Choisir une image étiquette initiale x_0 ;
- Porter le système à une température "assez élevée".
- **Répéter**
 - ◆ Calculer un nouvel état du système
 - ◆ Diminuer la Température
- **Jusqu'à** atteindre une température "assez basse".

Algorithme IV.2 Recuit simulé

Le concept de température d'un système physique n'a pas une équivalence directe avec le problème à optimiser. Le paramètre température T doit être simplement un paramètre de contrôle, indiquant le contexte dans lequel se trouve le système (stade de la recherche). En fait, lorsque la température est élevée (à la limite où $T \rightarrow \infty$) toutes les configurations sont équiprobables, ce qui permet de sortir des minima locaux de la fonction d'énergie. Dans ce cas, une baisse brutale de température T risquerait de faire figer le système(l'image) dans une configuration intermédiaire. Inversement, lorsque la température décroît (d'où le terme recuit) ces sauts en énergie deviennent rares et le système se stabilise au fond d'un minimum global (Fig IV.1).

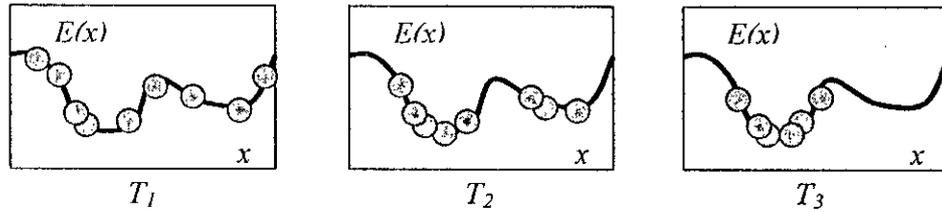


Fig. IV.1 Recherche du minimum global par le recuit simulé ($T_1 > T_2 > T_3$)

Bien que cet algorithme converge théoriquement vers le minimum global du critère MAP, cet avantage est loin d'être atteint en pratique, car on ne peut pas se placer dans les bonnes conditions (théoriques). En d'autres termes : « on n'a aucune garantie d'atteindre ce minimum global avec une quantité finie de calcul » [COQ-96].

Le calcul d'un nouvel état, dans l'algorithme IV.2, peut se faire soit avec l'échantillonneur de Gibbs, soit avec la dynamique de Metropolis. Cette dernière permet de ne pas explorer toutes les combinaisons possibles (ce qui est le cas de l'échantillonneur de Gibbs) mais de parcourir aléatoirement l'espace des états jusqu'à atteindre l'équilibre thermique.

Examinons à présent les deux techniques.

4.1.2.2. Dynamique de Metropolis

La dynamique de Metropolis permet de décider si une nouvelle configuration générée présente une variation de coût acceptable. Il permet de décider aussi de sortir des minima locaux quand le critère d'arrêt n'est pas encore atteint .

Après chaque passage d'un état (étiquette)de pixel $x'_{i,j}$ à un état $x_{i,j}$, on calcule la variation de la fonction de coût $\Delta E_{loc} = E_{loc}[x_{i,j}] - E_{loc}[x'_{i,j}]$. La transformation est acceptée selon la probabilité $p(u,v)$ telle que:

$$p(x'_{i,j}, x_{i,j}) = \exp(\Delta E_{loc} / T) \quad (IV.18)$$

Notons que dans cet algorithme:

- Toutes les transitions vers un état d'énergie inférieure est automatiquement retenue.
- Toute transition vers des états d'énergie supérieure est permise avec la probabilité $p(x'_{i,j}, x_{i,j})$ afin de pouvoir sortir de minimums locaux. Dans ce cas, la température T permet de contrôler l'amplitude des sauts (voir Fig IV.2)

l'algorithme de Metropolis, pour l'évaluation des états suivants, se schématise comme suit :

- ♦ Itération $r=0$;
- ♦ **Répéter**
 - ♦ **Pour chaque** pixel de l'image (i,j) :
 - Tirer une valeur $x_{i,j}$ de l'ensemble Λ (tirage aléatoire).
 - Calculer la variation de l'énergie locale :

$$\Delta E_{loc} = E_{loc}[x_{i,j}] - E_{loc}[x'_{i,j}]$$

Tirer aléatoirement $\varepsilon \in [0,1]$.

(**Critère de Metropolis**) : un nouvel état est accepté selon la règle suivante :

$$x'_{i,j} = \begin{cases} x_{i,j} & \text{si } \Delta E_{loc} \leq 0 \\ x_{i,j} & \text{si } \Delta E_{loc} > 0 \text{ et } \varepsilon < \exp(\Delta E_{loc} / T), \\ x'_{i,j} & \text{sinon} \end{cases}$$

- ♦ **FinPour**

$r=r+1$;

Jusqu'à critère de stabilité vérifié.

Algorithme IV.3 Dynamique de Metropolis

$x'_{i,j}$ est l'état du pixel (i,j) à l'itération r .

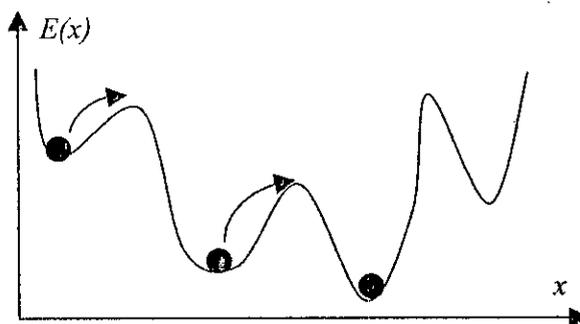


Fig. IV.2 Sauts des minimums locaux.

L'élément essentiel de cet algorithme (Algorithme IV.2) est la condition d'équilibre thermique qui joue un rôle important dans la qualité des solutions obtenues. Elle permet de contrôler la nature de la convergence du processus.

4.1.2.3. Critère de stabilité

La définition d'un bon critère de stabilité ou d'équilibre thermique est très importante, ceci dans le but d'approcher au mieux la limite. Dans un premier temps, nous avons testé quelques critères :

- ♦ Stabilité si le nombre moyen de pixels modifiés est supérieur à un seuil donné. (rejeté)
- ♦ Stabilité pour un nombre d'itération donné ; après quoi l'équilibre est atteint. (rejeté)
- ♦ On a abandonné ces deux critères du fait que l'un ne tenait pas compte des caractéristiques de l'image, et que l'autre ne prenait pas en compte l'altitude des variations d'énergie.
- ♦ Cependant, on constate l'absence du terme de l'énergie $E(x)$, dans la définition des deux critères. Afin de remédier aux inconvénients des deux critères, on a fait intervenir la fonction d'énergie dans la détermination du critère de stabilité. L'algorithme associé à ce critère est :

calculer l'énergie globale de l'état initial : $Moy = E^0(x)$;

calculer l'énergie globale du nouvel état, $E(x)$;

$Nombre_Fois = 0$;

SI ($|\frac{Moy - E(x)}{Moy}| < Seuil_Stabilité$)

$Nombre_Fois = Nombre_Fois + 1$;

Sinon

$Nombre_Fois = 0$;

$Moy = E(x)$;

FinSI

SI ($Nombre_Fois = Periode_Stabilité$) **Alors**

critère de stabilité vérifié.

Algorithme IV.4 Condition de stabilité

- ♦ D'après l'algorithme (IV.4) le critère de stabilité peut être résumé comme suit :
« L'équilibre thermique est atteint lorsque toutes les fluctuations énergétiques oscillent autour d'une certaine moyenne à un seuil donné et pendant une période donnée ».

4.1.2.4. Echantillonneur de Gibbs pour la segmentation

Cet algorithme a été proposé par Geman et Geman[GEM-84]. Le passage vers un nouvel état se fait par un tirage aléatoire selon la loi de distribution de Gibbs.

L'échantillonneur de Gibbs, calcule le nouvel état du système de la manière suivante:

Itération $r=0$;

Répéter

Pour chaque pixel de l'image (i,j) :

Pour chaque $g \in \Lambda = \{0, 1, \dots, G-1\}$

Calculer l'énergie locale $E_{loc}[g]$ de la classe g :

$$E_{loc}[g] = -M \frac{y_{i,j}^2}{2\sigma_k^2} + \text{Log} \left[\frac{y_{i,j}^{2M-1}}{(2\sigma_k^2)^M} \right] - \beta \sum_{(k,l) \in \eta_{i,j}} I(g, x_{k,l}^r)$$

Calculer la probabilité de conditionnelle locale :

$$p_g = \frac{\exp(E_{loc}[g]/T)}{\sum_{g \in \Lambda} \exp(E_{loc}[g]/T)}$$

FinPour

Effectuer un tirage aléatoire de $g \in \Lambda$ selon la loi p_g ;

Le nouvel état du pixel (i,j) est : $x_{i,j}^{r+1} = g$;

FinPour

$r=r+1$;

Jusqu'à un nombre d'itérations déterminé

Algorithme IV.5 Echantillonneur de Gibbs

Il est prouvé que si le nombre d'itérations tend vers l'infinie (ce qui est quasi impossible pratiquement) le processus ainsi construit converge vers en loi de Gibbs[COQ-96] et donc donne les meilleurs résultats.

4.1.3. Température initiale

L'algorithme de recuit simulé dépend du procédé du recuit qui se réfère à la diminution lente de la température T . Il est connu [GEM-84][DER-88] que si la température $T(r)$ employée à l'itération r satisfait la limite :

$$T(r) \geq \frac{c}{\log(r+1)} \quad (\text{IV.19})$$

pour une certaine constante c qui est indépendante de r . Alors le recuit simulée converge avec une probabilité de un vers le minimum global de la fonction d'énergie lorsque r tend vers l'infini.

Cependant, il existe des difficultés pratique dans l'implémentation du recuit. En premier, la constante c n'est pas facile à déterminer. En second, le recuit suggéré par (IV.19) est tellement lent qu'il nécessite un nombre d'itérations prohibitif. En d'autres termes, les conditions théoriques du recuit simulé sont trop sévère pour qu'elles soient vérifiées. En

pratique, la loi théorique est approchée par une loi exponentielle. A cause de cette approximation, la convergence vers un minimum global n'est plus garantie.

4.1.3.1. Température initiale

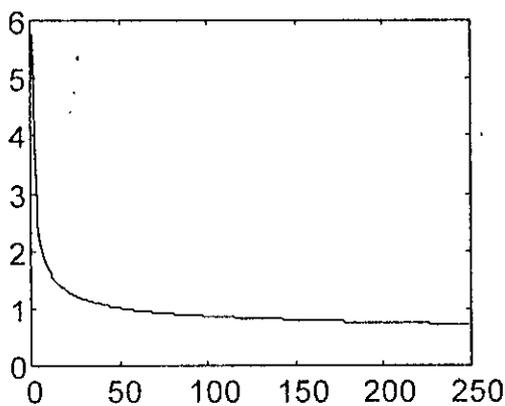
La température initiale T_0 doit être choisie telle que toutes les transitions puissent accepter une probabilité non nulle. Il est très difficile de trouver une telle valeur car elle est liée au maximum et le minimum d'énergie. En pratique, on choisit une température relativement faible pour assurer une convergence rapide. Dans notre réalisation nous avons choisi T_0 par essai et erreur.

4.1.3.2. Loi de décroissance de température

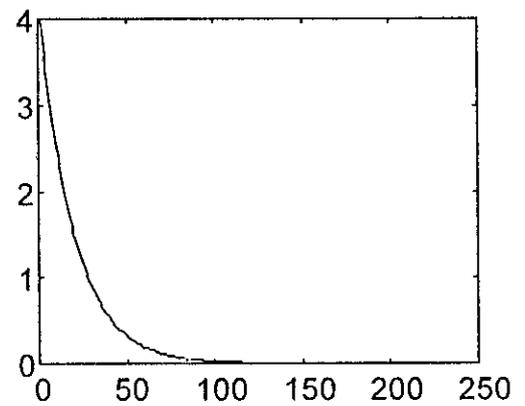
Le point le plus important est la loi de décroissance de la température. Les lois logarithmiques sont en général lentes (Fig IV.3 a). Pour cette raison, nous utilisons plutôt des lois exponentielles (Fig IV.3 b) :

$$T_{r+1} = c_0 \cdot T_r \quad (\text{IV.19})$$

Où $c_0 < 1$ est un constant proche de 1.



(a) $4/\log(r)$



(b) $0.95^r \cdot 4$

Fig IV.3. Loi de la température : (a) Loi logarithmique (b) Loi exponentielle

Remarque

Evidemment la température finale, $\lim_{r \rightarrow \infty} T_r = 0$; peut être seulement approximée par un nombre fini de valeurs de T_r . On peut arrêter le recuit lorsque le changement de la fonction d'énergie ΔE devenu inférieure à un certain seuil.

4.2. Algorithmes déterministes

Comme nous l'avons déjà mentionné, les algorithmes aléatoires sont très coûteux en temps de calcul. C'est pourquoi, on fait parfois appel aux algorithmes déterministes d'autant plus que le temps de traitement est pris en considération. Cependant, dans le cas où le critère est non convexe, tous les algorithmes de ce type sont optimaux. En ce sens, ils ne permettent d'atteindre qu'un minimum local de la fonction d'énergie et risquent de converger vers des estimations de qualité inférieure, surtout si l'initialisation n'est pas faite correctement. Par contre, si le critère à minimiser est convexe, l'utilisation d'un algorithme déterministe se trouve justifiée du moment où le minimum est unique.

4.2.1. Modes conditionnels itérés

Comme on l'a vu dans la section (IV.5), la segmentation au sens du MAP consiste à prendre comme estimée la valeur \hat{x} qui maximise la probabilité a posteriori. A cet effet, nous avons mis en œuvre la deuxième méthode ICM (Iterated Conditional Modes). Il est appliqué pour la première fois par Besag[BES-89], l'ICM est en réalité un échantillonneur de Gibbs à Température nulle. L'algorithme de relaxation déterministe ICM, calcule de façon itérative l'expression suivante :

$$P[X_{i,j} = x_{i,j} / X_{kl} = x_{kl}, Y = y, (k,l) \neq (i,j)] = P[Y_{i,j} = y_{i,j} / X_{i,j} = x_{i,j}] \times P[X_{i,j} = x_{i,j} / X_{kl} = x_{kl}, (k,l) \in \eta_{i,j}]$$

(IV.20)

Il affecte à l'étiquette du pixel courant (traité) le mode (le maximum) de la distribution conditionnelle locale (IV.20). D'où, le nom de ICM pour Iterated Conditional Modes donné à cet algorithme. Cette opération est répétée jusqu'à obtention de la stabilité de la segmentation. Cette méthode simple et rapide est convergente, puisque à chaque itération on diminue toujours l'énergie, mais tous comme les méthodes de gradient, elle converge sûrement vers un optimum local.

L'algorithme de l'ICM est alors décrit par les étapes suivantes :

- Choisir une configuration initiale x_0 ; l'itération $r=0$;

Répéter

Pour chaque pixel de l'image (i,j)

Mise à jours de \hat{x}_{ij} par l'étiquette qui maximise :

$$P[Y_{i,j} = y_{i,j} / X_{i,j} = x_{i,j}] \times P[X_{i,j} = x_{i,j} / X_{kl} = x_{kl}, (k,l) \in \eta_{i,j}]$$

FinPour

$r=r+1$;

Jusqu'à critère de stabilité vérifié.

Algorithme IV.5 Algorithme ICM

Cet algorithme est parfaitement déterministe dans la mesure où il n'y a aucun tirage aléatoire, les seuls paramètres qui influent sur le résultat final sont :

- Le nombre de balayages.
- L'ordre suivant lequel on balaye l'image.
- La configuration initiale.

Pour le critère de stabilité on a pris le même critère du recuit simulé (Algorithme 5.3).

4.2.2. Dynamique de Metropolis Modifiée

La dynamique de Metropolis modifiée (MMD) [KAT-94] [SZI-97] est une variante déterministe de l'algorithme de Metropolis. Les étapes de cet algorithme sont :

Soit x_0 une configuration initiale, $r = 0$ et $T = T_0$

- ♦ **Pour chaque** pixel de l'image (i,j) :

Tirer une valeur $x_{i,j}$ de l'ensemble Λ (tirage aléatoire).

Calculer la variation de l'énergie locale :

$$\Delta E_{loc} = E_{loc}[x_{i,j}] - E_{loc}[x'_{i,j}]$$

(**Critère MMD**) : un nouvel état est accepté selon la règle suivante :

$$x_{i,j}^{r+1} = \begin{cases} x_{i,j} & \text{si } \Delta E_{loc} \leq 0 \\ x_{i,j} & \text{si } \Delta E_{loc} > 0 \text{ et } \log(\varepsilon) < \frac{\Delta E_{loc}}{T}, \\ x'_{i,j} & \text{sinon} \end{cases}$$

- ♦ **FinPour**

$r = r + 1$;

où $\varepsilon \in (0,1)$ est un seuil constant fixé au début de l'algorithme.

- ♦ **Jusqu'à** critère de stabilité vérifié.

Décroître la température $T = T_{r+1}$ et continuer avec Etape 2 , jusqu'à la congélation du système

Algorithme IV.6 Principe de la Dynamique de Metropolis modifiée (MMD)

Pour des températures élevées, le comportement de l'algorithme est similaire aux algorithmes stochastiques (aléatoires) mais si la température est inférieure à un certain seuil, il devient déterministe. La 'longueur' de la phase 'pseudo-stochastique' est contrôlée par une constante utilisée dans les dynamiques modifiées. En effet, il est clair que si :

$$T \leq \frac{\Delta E_{loc}}{\log(\varepsilon)} \quad (\text{IV.21})$$

le saut vers des configurations d'énergie plus élevée n'est pas permis. Après un seuil de température

$$T_c = \frac{(\Delta E_{loc})_{\min}}{\log(\varepsilon)} \quad (\text{IV.22})$$

où $(\Delta E_{loc})_{\min} = \min_{g_1, g_2 \in \mathcal{A}} |E_{loc}(g_1) - E_{loc}(g_2)|$

alors la MMD entre dans la phase déterministe et se trouve bloqué dans un minimum local.

La différence entre l'algorithme de *Recuit Simulé* et l'algorithme MMD est le choix de ε dans l'étape 3 de l'Algorithme IV.3. Pour l'algorithme original, ε est choisi aléatoirement à chaque itération, alors que pour l'MMD ε est un seuil constant, qui est fixé au début de l'algorithme.

L'initialisation de MMD n'est pas vitale car la *phase pseudo-stochastique* donne une bonne configuration initiale pour la *phase déterministe*.

Il n'existe pas de formule explicite pour calculer ε . En pratique ε est proche de 1 si l'image est lisse. Si l'image est trop bruitée une valeur plus faible doit être assignée à ε .

5. MISE EN OEUVRE ET RESULTATS

Dans cette partie, nous nous proposons d'évaluer le modèle de segmentation pour chacun des algorithmes d'optimisation décrits. L'implémentation de notre application (segmentation des images SAR) est réalisée à l'aide du compilateur BORLAND C++ sous WINDOWS version 4.5. les différents tests sont effectués sur un PC AMD 450MHZ avec 32MO de RAM.

5.1 Initialisation des étiquettes

L'initialisation des algorithmes Metropolis, Gibbs et MMD est choisie en donnant des valeurs aléatoires à tous les pixels de l'image des étiquettes x_0 . Pour le cas de l'ICM, les étiquettes initiales sont choisies de sorte que $U_1(y/x)$ est maximale (IV.11). Ceci signifie l'estimation maximum de vraisemblance des étiquettes.

5.2. Paramètres

♦ Les écarts types σ_k sont déterminés en utilisant une méthode d'apprentissage supervisée (Fig IV.4). Ces valeurs sont données par l'estimateur de maximum de vraisemblance :

$$\hat{\sigma}_k^2 = \frac{\sum_{(i,j) \in S_k} y_{i,j}^2}{2 \text{cad}(S_k)} \quad (\text{IV.23})$$

où S_k est l'ensemble des pixels appartenant à l'ensemble d'apprentissage de la classe k .

♦ Les paramètres ε et β sont choisis par essai et erreur. Leurs valeurs pour les différentes images est donnée dans le tableau (IV.3).

5.3. Tests

Pour évaluer l'efficacité du modèle ainsi que les performances des algorithmes d'optimisation, on va tester notre application sur des images synthétiques et une image radar réelle (de Laghouat). Considérons maintenant deux images d'intensités de

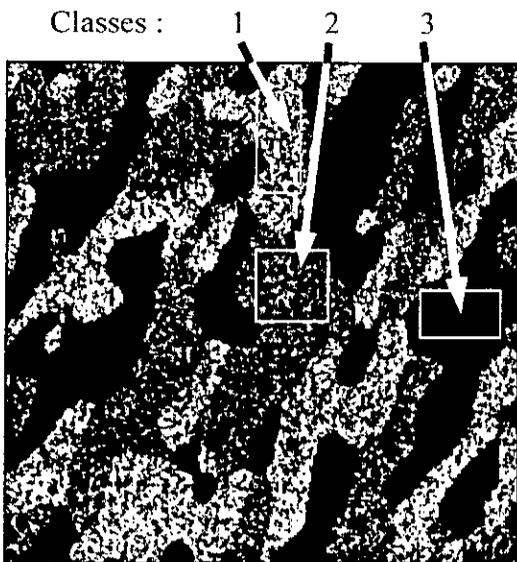


Fig IV.4 Ensembles d'apprentissages sur une image synthétique

référence de taille 256x256, composées de trois classes : une image (image Geman) générée artificiellement (Fig IV.6.a) et une autre image (image jain) générée par l'échantillonneur de Gibbs (Fig IV.8.a). Dans ces deux images, le rapport entre deux intensités successives est 6dB. Ensuite, les images amplitudes specklées correspondantes sont obtenues en multipliant les images originales par un speckle simulé 4-looks (Fig IV.6.b) et (Fig IV.8.b). Après, on considère une réelle (Fig I.11 Chapitre II).

Les figures (Fig IV.7), (Fig IV.9) et (Fig IV.10) montrent les résultats de segmentation de l'approche supervisée par applications des algorithmes RS (Metropolis), ICM, MMD, et l'échantillonneur de Gibbs.

Par une analyse des segmentations obtenus on remarque d'une part que toutes les méthodes ont réussi de détecter les régions. D'autre part on remarque le problème des points bruit qui existent à l'intérieur des régions de l'image résultat et le problème au niveau des frontières de chaque région. Le premier problème peut être résolu soit en choisissant β plus grand pour avoir des régions lisses ce qui risque de cacher une ou plusieurs régions (Fig IV.11.a) ou en utilisant un simple filtrage Médian (Fig IV.11.b). Le deuxième problème peut être résolu en utilisant le modèle adapté aux discontinuités [LI-96] qui n'a pas été étudié dans ce travail. Dans ce cas on utilise des fonctions vérifiant certaines conditions dont le rôle est diminué l'interaction entre des pixels voisins là où une discontinuité existe (voir annexe B).

Les résultats en temps de calcul et en pourcentage d'erreur de classification sont donnés au tableau IV.1 et IV.2 respectivement. On remarque que l'ICM expose un temps plus rapide que les autres algorithmes mais au prix d'un petit décalage en ce qui concerne l'erreur de classification des pixels. Ce qui permet de l'ICM d'être plus pratique surtout si l'initialisation est proche de la vraie solution.

La convergence de la fonction d'énergie $E(x)$ pour le cas de l'algorithme recuit simulé appliqué sur les trois images décrites, est donnée à la figure (Fig IV.5). On observe que la fonction d'énergie commence à osciller autour de la solution approchée après un certain nombre d'itérations. ce qui valide l'aspect théorique du recuit.

Le résultat de l'application de l'algorithme ICM sur une image texturée est donnée à la figure (Fig. IV.12). Ici nous avons considéré un modèle Gibbsien hiérarchique décrit dans

le chapitre III. Puisque les échantillons de l'image texturée sont indépendants, on utilise pour la loi de distribution jointe des observations l'expression suivante :

$$P(Y = y / X = x) = \prod_{(i,j) \in \mathcal{I}} P(Y_{v_{i,j}} = y_{v_{i,j}} / X_{i,j} = x_{i,j}) \quad (IV.24)$$

Où $v_{i,j}$ est un ensemble de voisins du pixel (i,j) plus le pixel (i,j) lui-même. $P(Y_{v_{i,j}} = y_{v_{i,j}} / X_{i,j} = x_{i,j})$ est une distribution de Gibbs sur cet ensemble de point. $y_{v_{i,j}}$ est une réalisation de Y sur cet $v_{i,j}$.

Ainsi, à chaque pixel l'ICM maximise l'expression :

$$P(Y_{v_{i,j}} = y_{v_{i,j}} / X_{i,j} = x_{i,j}) \times P[X_{i,j} = x_{ij} / X_{k,l} = x'_{k,l}, (k,l) \in \eta_{i,j}] \quad (IV.24)$$

ALGORITHMME \ IMAGE	ICM	RS	GIBBS	MMD
Geman	16.90 sec	17 min 54.67sec	55 min 31.40	13 min 48.25sec
Jain	16.20 sec	17 min 55.71sec	22 min 48.09	13 min 42.87sec
Radar	6.59 sec	11 min 4.54sec	6 min 7.61 sec	6 min 45.48sec

Tableau IV.1. Temps de calcul des différents algorithmes

ALGORITHMME \ IMAGE	ICM	RS	GIBBS	MMD
Gem	5,29%	5,12%	5,34%	5,17%
Jain	14,32%	13,15%	11,20%	13,69%

Tableau IV.2. Erreur de classification.

IMAGE	β	ε (MMD)
Geman	0,4	0,3
Jain	0,4	0,3
Radar	0,2	0,2

Tableau IV.3. Valeurs de β et ε

6. CONCLUSION

Nous venons de présenter dans ce chapitre quelques algorithmes d'optimisation de la fonction d'énergie de la modélisation statistique associée à l'estimation bayésienne. Dans cette dernière on a utilisé la loi de Rayleigh pour l'image observée, et la distribution de Gibbs pour l'image des étiquettes. Cette dernière est une fonction non convexe. Sa maximisation nécessite l'utilisation de deux algorithmes d'optimisation : stochastique et déterministe.

Les algorithmes stochastiques convergent théoriquement vers un minimum global de la fonction d'énergie, mais avec un temps insupportable souvent pour des espaces de configurations très grands. En revanche, les algorithmes déterministes convergent plus rapidement, mais présentent cependant l'inconvénient de se piéger dans les minima locaux de la fonction d'énergie et risquent donc de converger vers des estimations de qualité inférieure. En fait, ces performances dépendent de leur initialisation. Le choix de l'une ou l'autre des méthodes est lié aux exigences pratiques concernant la rapidité de calcul (applications en temps réel) et la qualité de la segmentation.

Cependant, la segmentation d'une image en différentes régions n'est pas une tâche aisée. La principale difficulté réside dans l'estimation des paramètres attachés au modèle statistique. De même, une segmentation est nécessaire pour cette estimation. Une solution à ce problème, est d'utiliser les méthodes de segmentation non supervisée dans lesquelles l'estimation et la segmentation se réalisent alternativement.

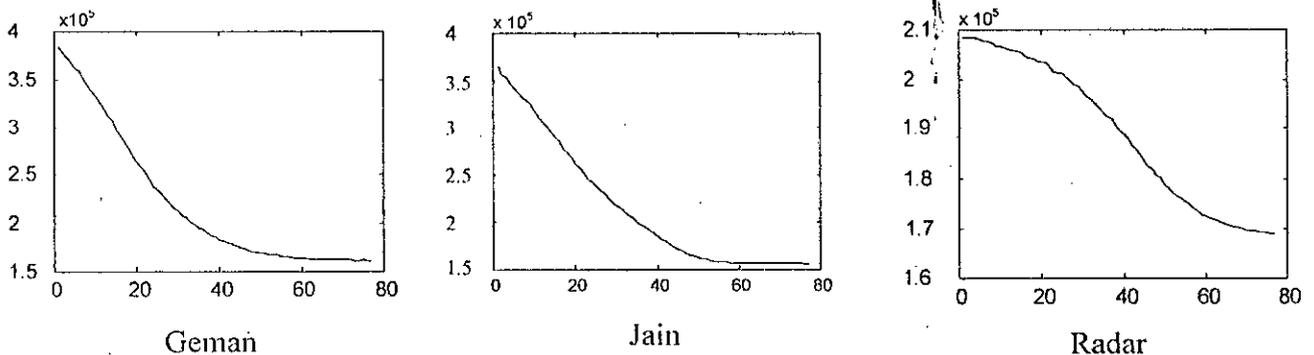
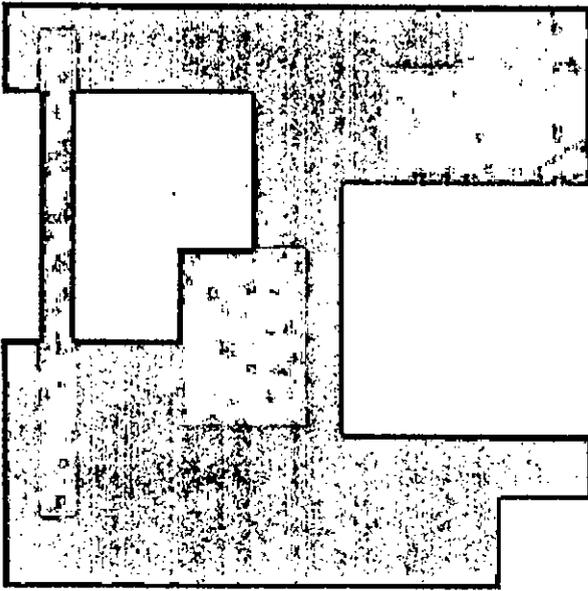
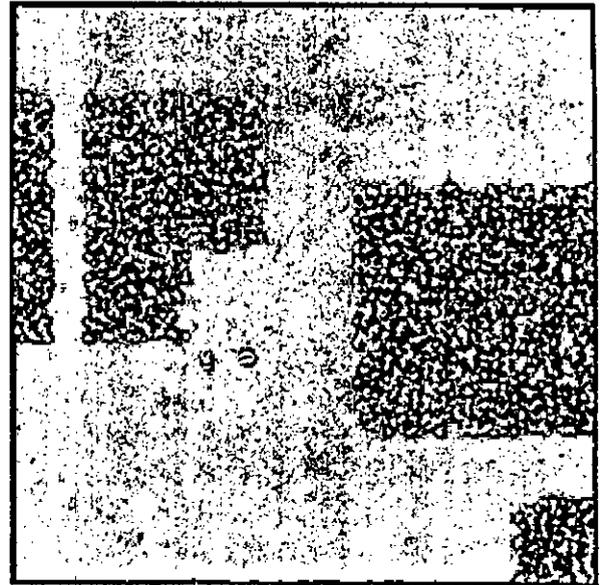


Fig IV.5 Convergence de la fonction d'énergie pour le cas du RS

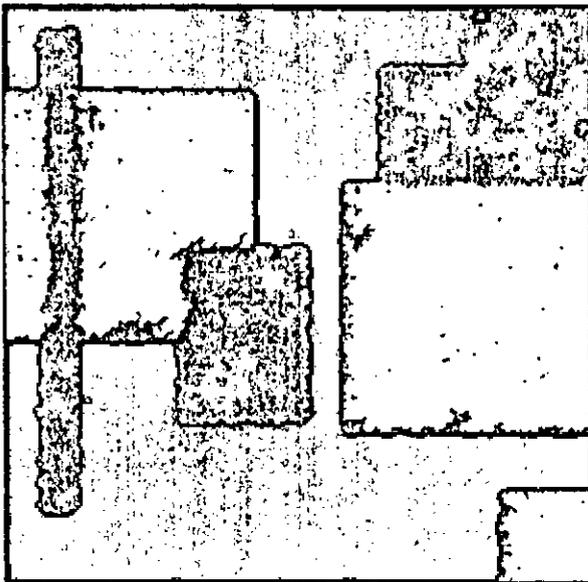


(a)

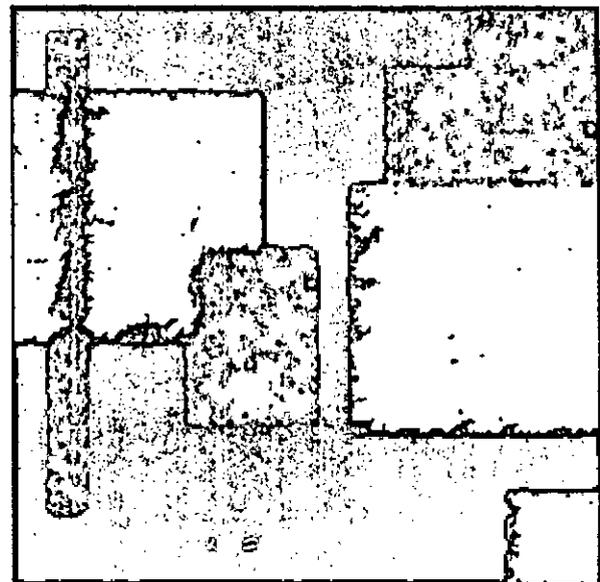


(b)

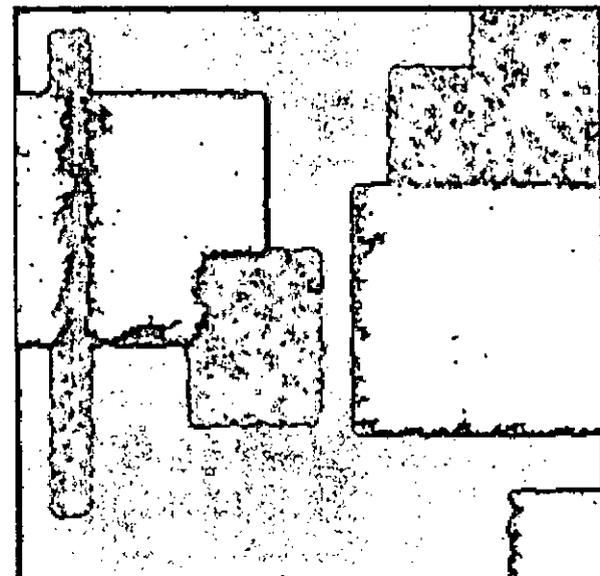
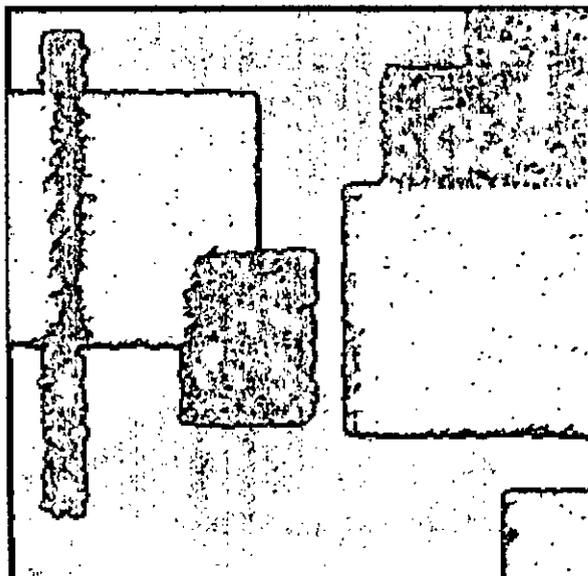
Fig IV.6. Image Geman synthétique (a) originale (b) specklée

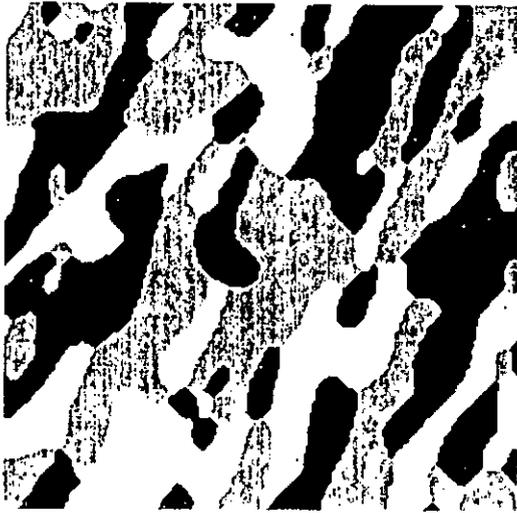


RS

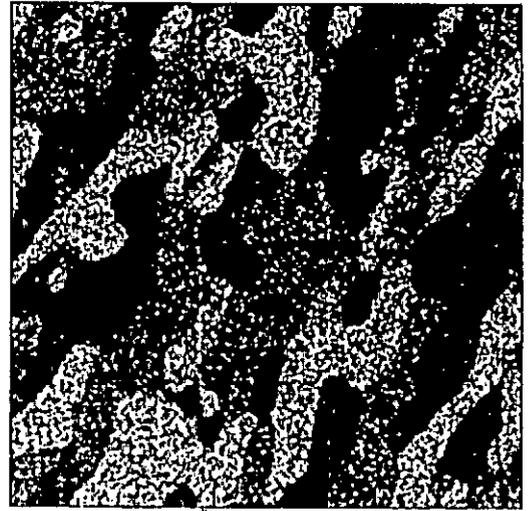


ICM



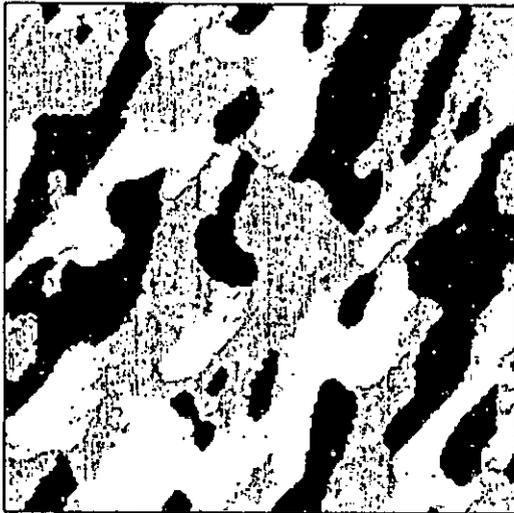


(a)

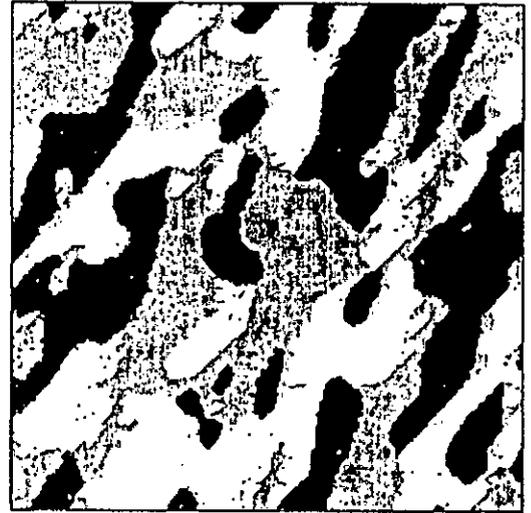


(b)

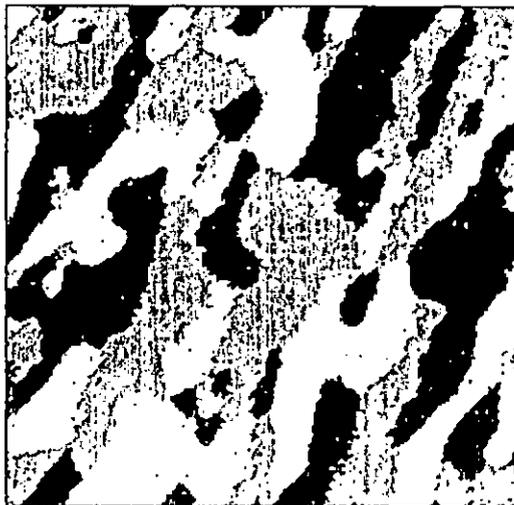
Fig IV.8. Image Jain synthétique (a) originale (b), specklée



RS



ICM



Gibbs



MMD

Fig IV.9. Résultats avec l'image Jain.

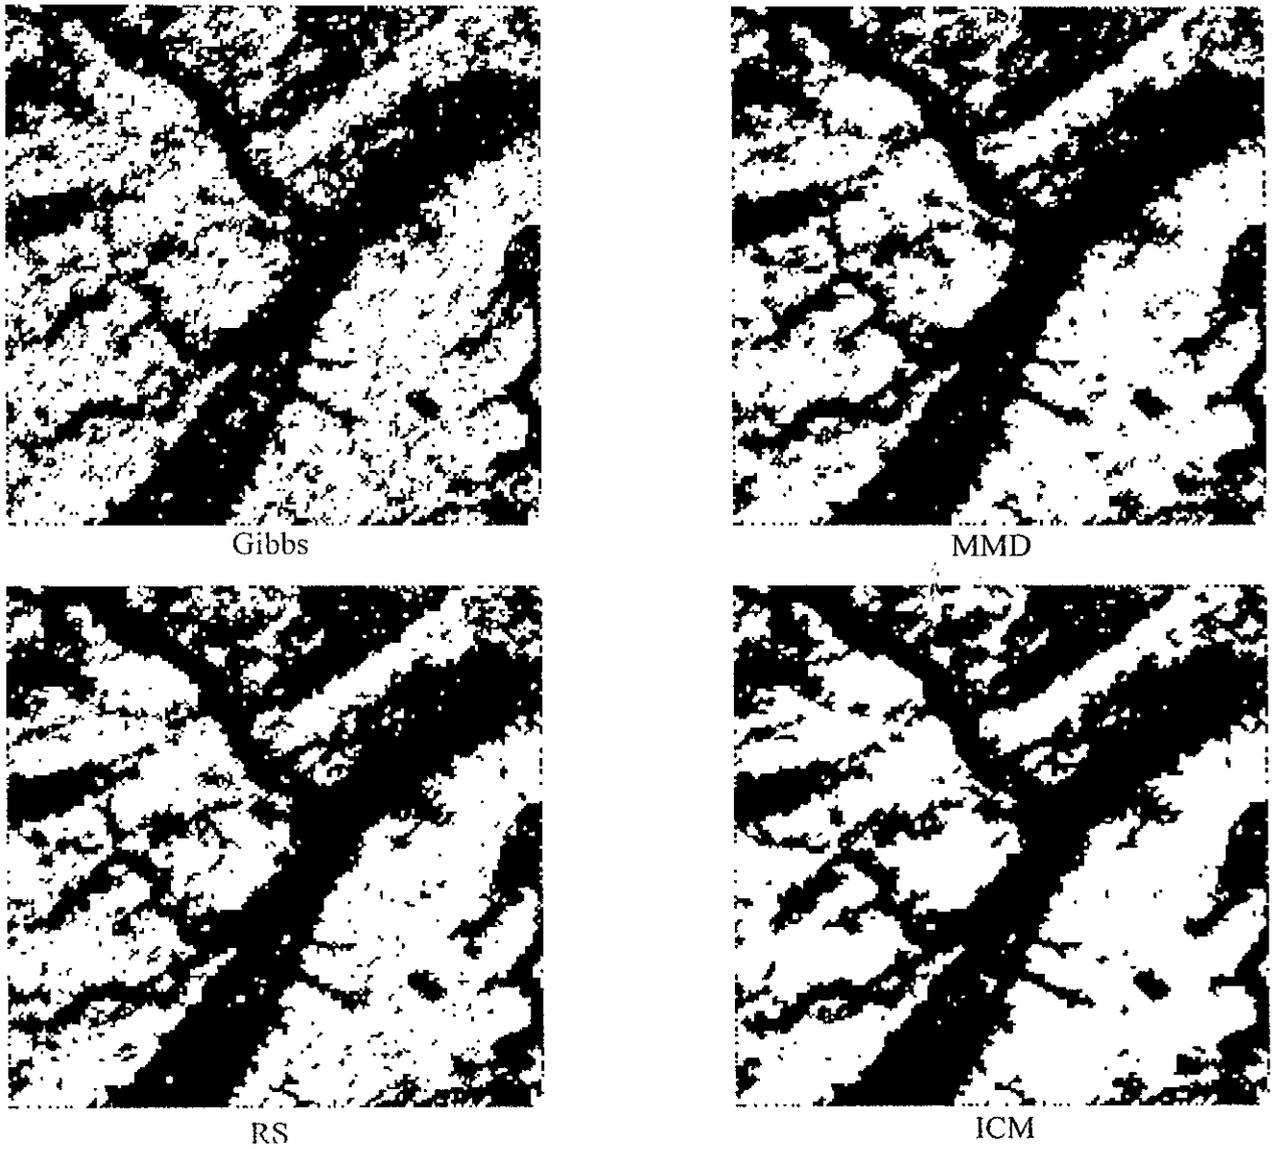


Fig IV.10. Résultats avec image radar réelle d'une région de Laghouat.

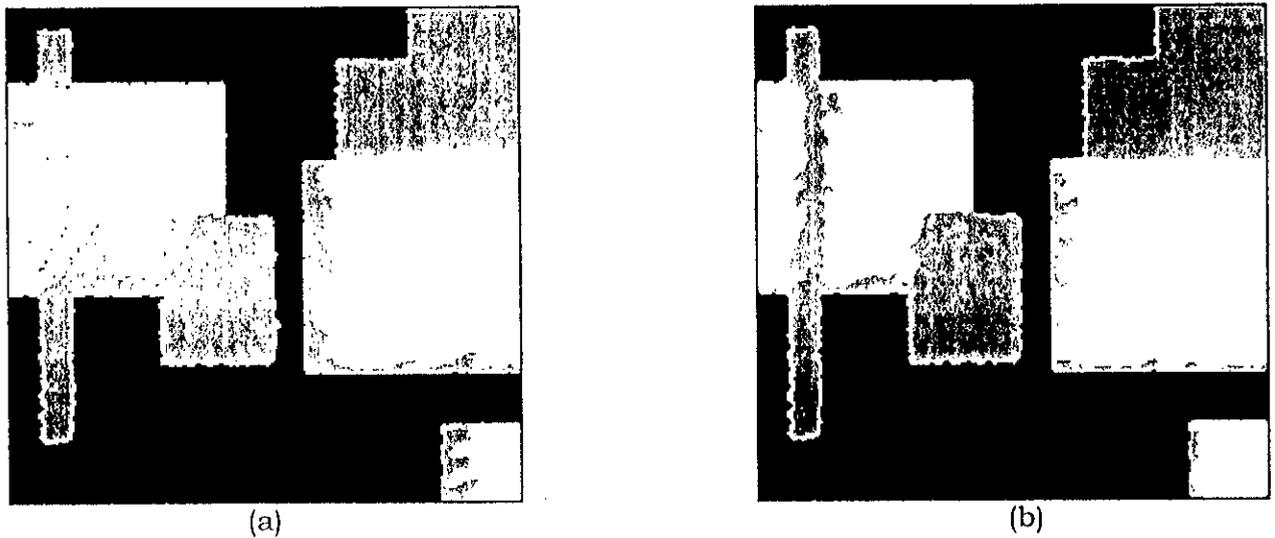
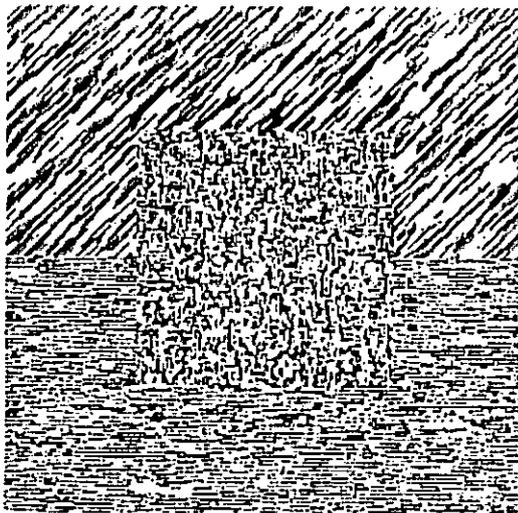
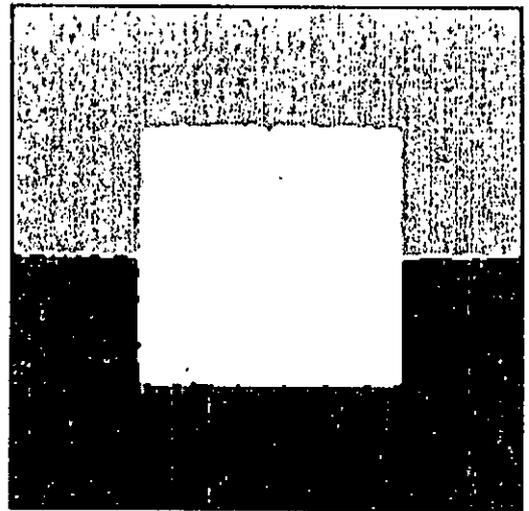


Fig IV.11. Segmentation par ICM (a) avec β élevé (0,9) (b) par filtrage médian du résultat de la fig IV.7 - ICM.



(a)



(b)

Fig IV.12. (a) Image texturée et (b) sa segmentation par ICM

CHAPITRE V

SEGMENTATION NON SUPERVISEE DES IMAGES SAR

1. INTRODUCTION

Un problème important associé aux techniques de segmentation par modélisation stochastique et l'estimation des paramètres. Ceci dû au fait que ces modèles sont généralement paramétriques spécifiés par un petit nombre de paramètres qu'on doit les estimés à partir de l'image. Si on connu à priori le nombre de classes et les paramètres des modèle ou si on utilise une échantillon d'apprentissage pour les déterminer on parle de segmentation supervisée. Par conséquent, les méthodes de segmentation utilisées dans le chapitre précédent sont non supervisées dans la mesure où l'opérateur sélectionne des échantillons représentatifs de chaque classe. Les résultats de cette technique sont de bonne qualité [DER-87][RIG-92].

Généralement on ne dispose pas d'informations sur le nombre de régions et de paramètres. Ainsi on doit donc les estimer à partir de l'image observée. Ceci entraîne le problème des données incomplètes dans la mesure ou on doit déterminer les paramètres et l'image segmentée à partir une seule réalisation. Ce problème est résolu par les algorithmes de segmentation non supervisée. Leur principe est d'estimer d'abord les paramètres, et de faire la segmentation ensuite en utilisant ceux-ci. Plusieurs méthodes basées sur cet aspect ont été proposées dans [DER-88][MIG-97][ZHA-94]. Dans le cadre des méthodes, on peut citer : l'algorithme EM (Expectation-Maximization)[ZHA-94], l'algorithme ICE (Iterative Conditional Estimation) [MIG-97] et l'algorithme de recuit simulé adaptatif [DER-88].

Dans ce chapitre on a étudié les méthodes d'estimation des paramètres pour le cas du modèle du speckle et le modèle des classes (distribution de Gibbs). Pour ce dernier cas, on a testé les méthodes du maximum de pseudo vraisemblance, des moindres carrées

(LSQR) et la méthode du codage. Pour la segmentation des images SAR, on a adopté les méthodes non supervisées basées sur l'algorithme EM et l'algorithme de recuit simulé adaptatif. La méthode ICE est étudiée mais n'est pas été testée puisqu'elle nécessite un temps de calcul élevé. En effet, à chaque itération de cette méthode on exécute l'échantillonneur de Gibbs (chapitre III) pour générer 50 images d'étiquettes. Pour chaque itération des algorithmes adoptés, les paramètres de speckle sont estimés par la méthode du maximum de vraisemblance et les paramètres du modèle de Gibbs sont estimés par la méthode du codage. En outre, la mise à jour des étiquettes est effectuée par l'ICM et le recuit simulé à température constante pour l'algorithme EM et le recuit simulé adaptatif respectivement. Les tests effectués sur des images synthétiques ont montré l'efficacité de la stratégie relativement à la bonne classification des pixels.

2. ESTIMATION DES PARAMETRES DU MODELE

Chacune des méthodes de segmentation exposées au chapitre précédent nécessite la connaissance des paramètres caractérisant la loi a priori, que l'on note Φ_x ainsi que les paramètres des lois conditionnelles de Y sachant X , que l'on note Φ_y . La phase de segmentation est donc précédée d'une phase d'estimation. Cette étape est indispensable lorsque l'on souhaite disposer de méthodes de segmentation automatique.

Pour présenter le principe général de l'estimation, supposons que la modélisation employée utilise une fonction d'énergie $U(y|x)$ dépendant du vecteur des paramètres $\Phi = (\Phi_x, \Phi_y)$, que nous noterons alors $U(y, \Phi)$. Face à une configuration x observée, le problème est alors d'estimer le vecteur $\hat{\Phi}$ du vecteur des paramètres qui « correspond le mieux » à cette réalisation. Ceci ne peut être défini que si l'on choisit un critère permettant de quantifier l'adéquation entre Φ_0 vraie vecteur des paramètres, et $\hat{\Phi}$ sachant x . Ceci explique qu'il puisse exister plusieurs estimateurs en fonction du critère choisi.

L'estimation des paramètres du modèle de l'image à partir d'une seule réalisation nécessite une hypothèse d'ergodicité. Ainsi on suppose que les caractéristiques locales extraites à différents endroits d'une réalisation du champ sont équivalentes à celles extraites sur plusieurs réalisations, ce qui permet de disposer à partir d'une seule image observée d'une grande quantité d'observations. Les méthodes d'estimation se placent, pour la plupart, dans le cadre stationnaire.

2.1. Estimation supervisée

A partir de la réalisation de X sur une partie de l'image, on parvient à estimer assez simplement dans le cas des méthodes contextuelles les paramètres Φ_x et Φ_y . Les lois a priori sont estimées par les fréquences empiriques de chacune des configurations, relatives à un contexte, présentes sur la zone d'apprentissage. L'estimation des paramètres des lois conditionnelles s'obtient en partitionnant les observations en fonction du type de configuration dont elles sont issues et en calculant sur chacun des sous-ensembles les moments empiriques. L'estimation des paramètres pour les méthodes globales est plus délicat. Une solution est utilisée, notamment la pseudo-vraisemblance proposée par Besag [BES-89].

2.2 Estimation non supervisée

Dans ce cas il faut estimer Φ_x et Φ_y uniquement à partir de l'observation Y . Le problème de l'estimation d'un mélange de lois a fait l'objet de nombreuses publications et divers algorithmes ont été proposés. Dans le cadre des méthodes contextuelles, nous pouvons citer deux méthodes classiques d'estimation : l'algorithme Expectation Maximization (EM) proposé par Dempster et al. [ZHA-94] et l'algorithme de recuit simulé adaptatif proposé par Derin et al. [DER-88]. Plus récemment, une méthode générale d'estimation a

été proposée par Pieczynski [MIG-97], il s'agit de l'algorithme Iterative Conditional Estimation (ICE).

Lors de l'estimation de mélange de lois, se pose le problème de la détermination du nombre de composants du mélange (nombre de classes). Nous ne l'avons pas abordé dans ce mémoire, le nombre de classes étant supposé connu. Cependant il existe des méthodes permettant de répondre à ce besoin. Citons en premier lieu l'algorithme SEM qui à partir d'un majorant du nombre de composants, détermine le nombre de composants présents dans le mélange. Nous pouvons également utiliser un critère permettant de décider, à partir de plusieurs estimations avec un nombre de composants différent dans le mélange, du nombre de classes idéal. Citons notamment le critère Minimum Description Length (MDL) proposé par Schwarz [FIG-98].

3. ESTIMATION DES PARAMETRES DU BRUIT

Les paramètres de bruit sont ceux qui caractérisent les distributions conditionnelles $P(Y = y / X = k)$ pour chacune des classes qu'on désigne par le vecteur Φ_y . Ainsi, pour les images SAR multilook où ces distributions suivent la loi Gamma, on a $\Phi_y = [\sigma_1^2, \sigma_2^2, \dots, \sigma_K^2, M]^T$. Les variances σ_k^2 sont estimés en utilisant l'estimateur du maximum de vraisemblance donné par :

$$\hat{\sigma}_k^2 = \frac{1}{\text{card}(L_k)} \cdot \sum_{(i,j) \in L_k} y(i,j) \quad k=0,1,\dots,G-1 \quad (\text{V.1})$$

où L_k est un ensemble des pixels qui appartient à la classe k .

L'estimation est meilleure lorsque la taille de L_k est grande.

Généralement, le paramètre M est supposé connu. Cependant, dans le cas où les images ont subi un traitement préalable en niveau de gris, il serait commode d'estimer M [DER-88]. Du fait qu'on a $E\{Y\} = M \cdot \text{var}\{Y\}$, alors il est raisonnable d'estimer M par :

$$\hat{M} = \frac{\langle y \rangle^2}{\langle \text{var}(y) \rangle} \quad (\text{V.2})$$

où $\langle y \rangle$ et $\langle \text{var}(y) \rangle$ sont la moyenne et la variance empiriques données par :

$$\langle y \rangle = \frac{1}{\text{card}(L)} \cdot \sum_{(i,j) \in L} y(i,j) \quad (\text{V.3})$$

et

$$\langle \text{var}(y) \rangle = \frac{1}{\text{card}(L)} \cdot \sum_{(i,j) \in L} (y(i,j) - \langle y \rangle)^2 \quad (\text{V.4})$$

4. ESTIMATION DES PARAMETRES DU CHAMP DE GIBBS

4.1. Méthode du maximum de vraisemblance (MV)

Pour l'estimateur du maximum de vraisemblance, on fixe une suite croissante D_n de sous ensembles convexes de L et on cherche le vecteur Φ_x qui maximise la vraisemblance définie à partir de la distribution de Gibbs restreinte à D_n :

$$P_{\Phi_x, n}(x) = \frac{1}{Z_n(\Phi_x)} \exp(-U(x, \Phi_x)) \quad (\text{V.5})$$

Par ailleurs, il est souhaitable qu'un estimateur s'approche de plus en plus du vecteur Φ_x quand la taille de D_n tend vers l'infini, c'est à dire quand n tend vers l'infini. On dit alors que l'estimateur est consistant.

Du fait que l'utilisation de l'estimateur MV est difficile même parfois impossible, on applique alors l'estimateur du maximum de pseudo-vraisemblance. Il est obtenu en maximisant la fonction :

$$Q_n(\Phi_x) = \prod_{s \in D_n} P_{n, \Phi_x}(x_s / x_r, r \in \eta_s) \quad (\text{V.6})$$

où x est la réalisation observée du champ de loi P_{n, Φ_x} .

Cette expression est plus simple à exploiter, en particulier quand l'énergie $U(x, \Phi_x)$ est une fonction linéaire du paramètre. La fonction $\log(Q_n(\Phi_x))$ est alors convexe et on peut utiliser une méthode de descente de gradient pour obtenir . Pour certaines hypothèses, on montre que l'estimateur ainsi obtenu est consistant (COQ-96):

$$\forall \varepsilon > 0, \lim_{n \rightarrow \infty} P\left(\left| \hat{\Phi}_n - \Phi_0 \right| < \varepsilon \right) = 1 \quad (\text{V.7})$$

où $\hat{\Phi}_n$ est le vecteur des paramètres estimé et Φ_0 est le vecteur des paramètres exactes.

4.2. Méthode de codage(CM)

Cette méthode est une version modifiée de l'estimateur pseudo-vraisemblance. Elle est basée sur la stratégie de codage de Besag [BES-89]. En effet, la maille L est divisée en

sous ensembles disjoints de pixels appelés codages. Chaque codage est choisi de telle sorte que ses pixels sont indépendants. Ceci peut être réalisé en séparant les pixels de la maille L tel que si (i,j) et (k,l) appartiennent au même codage alors $x(i,j)$ et $x(k,l)$ ne sont pas voisins au sens de Markov(III.12).

Un système de voisinage de premier ordre nécessite deux codage pour l'estimation des paramètres. Un système de voisinage de second ordre nécessite quatre codage pour que les blocs de 3×3 pixel ne s'interfèrent pas. Ces codages sont montrés à la figure V.1.

1	2	1	2	1	2	1	2	1	2
2	1	2	1	2	1	2	1	2	1
1	2	1	2	1	2	1	2	1	2
2	1	2	1	2	1	2	1	2	1
1	2	1	2	1	2	1	2	1	2
2	1	2	1	2	1	2	1	2	1
1	2	1	2	1	2	1	2	1	2
2	1	2	1	2	1	2	1	2	1
1	2	1	2	1	2	1	2	1	2
2	1	2	1	2	1	2	1	2	1

(a)

1	2	1	2	1	2	1	2	1	2
3	4	3	4	3	4	3	4	3	4
1	2	1	2	1	2	1	2	1	2
3	4	3	4	3	4	3	4	3	4
1	2	1	2	1	2	1	2	1	2
3	4	3	4	3	4	3	4	3	4
1	2	1	2	1	2	1	2	1	2
3	4	3	4	3	4	3	4	3	4
1	2	1	2	1	2	1	2	1	2
3	4	3	4	3	4	3	4	3	4

(b)

Fig.V.1. Les codages liés au système de voisinage
(a) de premier ordre (b) de second ordre.

Soit C_i l'ensemble des sites du $i^{\text{ème}}$ codage

Appliquant la formule de Bayes et utilisant la propriété de Markov, on aboutira à l'expression suivante du logarithme de la distribution jointe des variables aléatoires $X(i,j)$ appartenant à C_i

$$L_i(\Phi_x) = \sum_{s \in C_i} \ln(P(s | t \in \eta_s)) \quad (\text{V.8})$$

où s et t représentent $x(i,j)$ et $x(k,l)$ respectivement et η_s est le vecteur des valeurs des voisinages du site (i,j) donné par :

$$\eta_s = [u_1, u_2, u_3, u_4, v_1, v_2, v_3, v_4]^T \quad (\text{V.9})$$

où les voisinages u_i et v_i sont montrés à la figure V.2 :

v_1	u_2	v_2
u_1	s	u_3
v_4	u_4	v_3

Fig.V. 2. Le système de voisinage η_s du site s

Le modèle de Gibbs utilisé dans ce travail est caractérisé par le vecteur des paramètres Φ_x :

$$\Phi_x = [\beta_1, \beta_2, \beta_3, \beta_4]^T \quad (\text{V.10})$$

on définit le vecteur :

$$\Theta(s, \eta_s) = \left[\left(I(s, u_1) + I(s, u_3) \right), \left(I(s, u_2) + I(s, u_4) \right), \right. \\ \left. \left(I(s, v_2) + I(s, v_4) \right), \left(I(s, v_1) + I(s, v_3) \right) \right] \quad (\text{V.11})$$

où

$$I(z_1, z_k) = \begin{cases} -1 & \text{si } z_1 = z_k \\ 1 & \text{sinon} \end{cases} \quad (\text{V.12})$$

soit $V(s, \eta_s, \Phi_x)$ la somme des fonctions potentielles de toutes les cliques qui contiennent le site de s :

$$V(s, \eta_s, \Phi_x) = \sum_{c: s \in c} V_c(x) \quad (\text{V.13})$$

pour le modèle de Gibbs choisi, cela peut être écrit sous la forme :

$$V(s, \eta_s, \Phi_x) = \Theta^T(s, \eta_s) \cdot \Phi_x \quad (\text{V.14})$$

Ainsi, la distribution conditionnelle locale au site de s s'écrit :

$$P(s|t \in \eta_s) = \frac{\exp(-V(s, \eta_s, \Phi_x))}{\sum_{s \in \Lambda} \exp(-V(s, \eta_s, \Phi_x))} = \frac{\exp(-\Theta^T(s, \eta_s) \cdot \Phi_x)}{\sum_{s \in \Lambda} \exp(-\Theta^T(s, \eta_s) \cdot \Phi_x)} \quad (V.15)$$

En substituant cette dernière équation dans (V.8) on obtient :

$$L_i(\Phi_x) = \sum_{s \in C_i} \log \left(\frac{\exp(-\Theta^T(s, \eta_s) \cdot \Phi_x)}{\sum_{s \in \Lambda} \exp(-\Theta^T(s, \eta_s) \cdot \Phi_x)} \right) \quad (V.16)$$

l'estime $\hat{\Phi}_x^i$ du vecteur de paramètre Φ_x pour le i^{eme} codage est obtenue par annulation du gradient de $L_i(\Phi_x)$ par rapport à Φ_x . Ceci conduit à un ensemble d'équations non-linéaires qui peuvent être résolus par les méthodes numériques telle que la méthode de Newton Raphson. Une forme adéquate de ces équations, associée au modèle utilisé dans notre travail pour une implémentation efficace de cette méthode, est donnée en annexe C. Finalement, l'estimateur de la méthode de codage est défini par :

$$\hat{\Phi}_x = \frac{1}{N_c} \cdot \sum_{i=1}^{N_c} \hat{\Phi}_x^i \quad (V.17)$$

Où N_c est le nombre de codage.

4.3. Méthode des moindres carrés (LSQR)

Vu de quelques difficultés pratiques impliquées dans l'utilisation de la méthode CM, Derin et Elliot [DER-87] ont proposé la méthode LSQR pour l'estimation du paramètre de la distribution de Gibbs. Cette méthode est basée sur une technique d'histogramme et la méthode de moindre carrées classique.

$$\frac{P(s, \eta_s)}{P(\eta_s)} = P(s|\eta_s) = \frac{\exp(-V(s, \eta_s, \Phi_x))}{W(\eta_s, \Phi_x)} \quad (V.18)$$

Où $P(s|\eta_s)$ est la distribution jointe des variables aléatoires définis sur la fenêtre 3x3 centré sur le site de s et $P(\eta_s)$ est la distribution jointe des variables aléatoires définis sur le voisinage η_s seulement, alors il s'en suit que :

$$\frac{P(s, \eta_s)}{P(\eta_s)} = P(s|\eta_s) = \frac{\exp(-V(s, \eta_s, \Phi_x))}{\sum_{s \in \Lambda} \exp(-V(s, \eta_s, \Phi_x))} \quad (V.19)$$

en réarrangeant (V.19) on obtient :

$$\frac{\exp(-V(s, \eta_s, \Phi_x))}{P(s, \eta_s)} = \frac{\sum_{s \in \Lambda} \exp(-V(s, \eta_s, \Phi_x))}{P(\eta_s)} \quad (\text{V.20})$$

Considérant le membre gauche de (V.20) pour deux valeurs distinctes de s , i.e. $s=j$ et $s=k$, on aura :

$$\exp(-V(j, \eta_s, \Phi_x) + V(k, \eta_s, \Phi_x)) = \frac{P(j, \eta_s)}{P(k, \eta_s)} \quad (\text{V.21})$$

prenant le logarithme de (V.21) et remplaçant $V(s, \eta_s, \Phi_x)$ par (V.14) on aboutit :

$$(\Theta(j, \eta_s) - \Theta(k, \eta_s))^T \cdot \Phi_x = \ln \left(\frac{P(j, \eta_s)}{P(k, \eta_s)} \right) \quad (\text{V.22})$$

dans (V.22), le vecteur $(\Theta(j, \eta_s) - \Theta(k, \eta_s))$ est déterminé facilement pour toute valeurs j et k et tout voisinage η_s tant que Φ_x est le vecteur à estimer. Le problème qui reste maintenant est comment déterminer $P(s, \eta_s)$ pour toutes les combinaisons (s, η_s) , en utilisant qu'une seule réalisation. Cela peut être réalisé au moyen d'une technique d'histogramme. En effet, si l'image est composée de K_1 blocs distinctes de taille 3×3 et si le nombre de blocs de type (s, η_s) est $N(s, \eta_s)$, alors $P(s, \eta_s)$ est estimé par :

$$\hat{P}(s, \eta_s) = \frac{N(s, \eta_s)}{K_1} \quad \text{Pour tout } s \in \Lambda \quad (\text{V.23})$$

En substituant par toutes les valeurs possibles de η_s dans (V.22) ainsi par toutes les paires distinctes (j, k) on obtient un système linéaire dont le nombre d'équations est supérieur au nombre d'inconnus. Par conséquent, on utilise la méthode de moindres carrés pour le résoudre.

5. SEGMENTATION NON SUPERVISEE

5.1. Le problème des Données incomplètes

Dans le but d'implémenter les procédures de segmentation par modélisation, d'une part on a besoin des paramètres du modèle $\Phi = (\Phi_x, \Phi_y)$. Cependant, dans la plupart du temps, ces paramètres sont inconnus et doivent être estimés. D'autre part pour les estimer, on doit disposer d'une réalisation du champ des régions X (image segmentée). Une solution raisonnable à ce problème serait l'estimation des paramètres et la segmentation de l'image récursivement. Il existe plusieurs algorithmes pour résoudre ce

problème, nous pouvons citer l'algorithme ICE (Iterative Conditional Estimation), l'algorithme du recuit simulé adaptatif et l'algorithme EM (Expectation Maximization). Dans ce travail, nous avons implémenté les deux derniers algorithmes pour calculer les estimateurs de type maximum de vraisemblance (ML) des paramètres à partir des données incomplètes ainsi nous avons fait appel à l'algorithme ICE. En effet, soit $W=(Y, X)$ un champ aléatoire qui représente la composition du champ de l'image observé Y et le champ des régions X non observé (image régions). Par convention, Y est appelé données incomplètes et W est appelé données complètes.

5.2. Algorithme ICE

La méthode d'estimation de mélange de lois Iterative Conditional Estimation (ICE) a été entamée dans la littérature par plusieurs auteurs, une modification a ensuite été présentée dans [MIG-97].

Le principe général est le suivant : nous considérons un estimateur $\hat{\Phi}(X, Y) = (\hat{\Phi}_x, \hat{\Phi}_y)$ défini à partir des données complètes $(X; Y)$ que nous approchons par une fonction de Y . La meilleure approximation au sens de l'erreur quadratique moyenne est l'espérance conditionnelle de $\hat{\Phi}(X, Y)$ sachant Y notée $E[\hat{\Phi}(X, Y)/Y]$. Le calcul de l'espérance conditionnelle se fait de la façon itérative :

$$\Phi_x^{[k+1]} = E_k [\hat{\Phi}_x | Y = y] \quad (V.24)$$

$$\Phi_y^{[k+1]} = E_k [\hat{\Phi}_y | Y = y] \quad (V.25)$$

Sachant que E_k est l'espérance conditionnelle correspondant à $\Phi^{(k)}$.

Lorsque E_k n'est pas explicitement calculable on peut approcher l'espérance conditionnelle par la moyenne empirique sur un ensemble de réalisations, cela en vertu de la loi des grands nombres. Il suffit ainsi simuler n réalisations indépendantes $(x(1), x(2), \dots, x(n))$ de X selon la loi conditionnelle $P_{X/Y, \Phi^{(k)}}(x/y, \Phi^{(k)})$ et poser :

$$\Phi_x^{[k+1]} = \frac{1}{n} \cdot [\Phi_x(x_{(1)}) + \dots + \Phi_x(x_{(n)})] \quad (V.26)$$

$$\Phi_y^{[k+1]} = \frac{1}{n} \cdot [\Phi_y(x_{(1)}, y) + \dots + \Phi_y(x_{(n)}, y)] \quad (V.27)$$

Dans notre application, $\Phi_y = \sigma^2$ pour un bruit speckle pleinement développé. Pour cela, on utilise l'équation (V.1) pour estimer les $\Phi_y(x_{(i)}, y)$. Par ailleurs, $\Phi_x(x_{(i)})$ sont estimés par l'une des méthodes décrites soit par la méthode de codage ou la méthode LSQR. ainsi, l'algorithme ICE se résume comme suit :

1. Soit $k = 0$, initialiser $\hat{\Phi}^{(0)}$.

2. Générer n réalisations des champs des classes $(x_{(1)}, x_{(2)}, \dots, x_{(n)})$ selon la loi $P_{x|Y, \Phi^{(k)}}(x/y, \Phi^{(k)})$ par l'utilisation de l'échantillonneur de Gibbs.
3. Pour chaque réalisation $x_{(i)}$, le vecteur des paramètres Φ_x est estimé par la méthode de codage ou la méthode LSQR et Φ_y est estimé par la méthode de maximum de vraisemblance (V.1).
4. $\Phi_x^{[k+1]}$ et $\Phi_y^{[k+1]}$ sont obtenus à partir $(\Phi_x(x_{(i)}), \Phi_x(x_{(i)}, y))_{i=1, \dots, n}$ par (V.26) et (V.27).
5. Continuer les étapes 2 à 5 jusqu'à ce $\Phi^{(k)}$ se stabilise.
6. Faire la segmentation des images en utilisant le vecteur paramètre $\Phi^{(k)}$ trouver dans l'étape 5 au moyen des algorithmes d'optimisation vus dans le chapitre IV.

5.3. L'algorithme de recuit simulé adaptatif

Cet algorithme de segmentation est fondamentalement l'algorithme de RS interrompu à des intervalles réguliers pour l'estimation des paramètres inconnus. En d'autres termes, l'algorithme produit une segmentation en utilisant les estimations courantes des paramètres et par la suite détermine des estimations de paramètre en utilisant la segmentation courante. Pour la segmentation, un certain nombre d'itérations (par exemple, 10) de RS est utilisées entre chaque mise à jour des paramètres. Les paramètres de distribution MLL (processus de région) sont estimés à partir de la segmentation courante en utilisant la méthode de codage.

Il est à noter que les résultats obtenus sont meilleures si nous effectuons les itérations en deux étapes. Dans la première étape, nous effectuons un ensemble d'itérations sans recuit (diminution de la température) et estimons par intermittence les paramètres. À la fin de cette étape, les estimations des paramètres sont notées. La deuxième étape se compose d'un ensemble d'itérations avec recuit et utilise les estimations des paramètres obtenues à la fin de la première étape. Nous effectuons 100 itérations dans chacune des deux étapes, ainsi ayant pour résultat un total de 200 itérations.

Nous présentons maintenant le schéma spécifique de l'algorithme utilisé.

A. Initialisation

1. Initialiser les paramètres $(\sigma^2)_k$ en utilisant dix itérations de l'algorithme de K moyennes.

B. Algorithme principal d'estimation

Faites les étapes 2 à 4 dix fois.

2. Dix itérations de la mise à jour pour la segmentation en utilisant le recuit simulé à température constante, ce qui permet de générer une réalisation de champ de Gibbs
3. Estimer par la méthode du codage des paramètres $\beta_i, i=1 \dots 4$ de distribution de MLL.

4. Estimer les paramètres de speckle $(\sigma^2)_{k=1..C}$ de chaque classe.

C. Segmentation

5. cent itérations de RS (avec diminution de la température) pour la segmentation.

5.4. L'algorithme EM

Le problème des données incomplètes décrit dans la section précédente consiste à estimer l'ensemble des paramètres en se basant seulement sur les données incomplètes Y . Ce problème est très compliqué, en utilisant l'approche ML conventionnelle par le fait que la partie des données x est absente. L'algorithme EM est une technique efficace pour résoudre ce problème. Soit $P(W / \Phi) = P(Y, X / \Phi)$ la densité de probabilité des données complètes W (la densité conjointe de X et Y), où Φ est le vecteur de paramètre à déterminer, et donnant un estimateur initial $\hat{\Phi}^{(0)}$. Alors, à la $p^{\text{ième}}$ itération, l'algorithme EM procède en deux étapes :

Etape E : Calculer l'espérance conditionnelle :

$$Q(\Phi / \hat{\Phi}^{(p)}) = E[\log(P(W / \Phi)) / Y, \hat{\Phi}^{(p)}] \quad (\text{V.28})$$

Etape M : Trouver $\hat{\Phi}^{(p+1)}$ qui maximise $Q(\Phi / \hat{\Phi}^{(p)})$:

$$\hat{\Phi}^{(p+1)} = \arg \max_{\Phi} Q(\Phi / \hat{\Phi}^{(p)}) \quad (\text{V.29})$$

L'obstacle principal lors de l'implémentation de l'algorithme EM réside dans la difficulté de trouver une expression analytique de l'espérance conditionnelle $Q(\Phi / \hat{\Phi}^{(p)})$ dans l'étape E. Ceci n'est facile que pour le cas des modèles simples. Dans la section qui suit, on propose une procédure qui produit récursivement les estimateurs des paramètres ainsi que la segmentation, qui correspond au modèle statistique de l'image SAR, en se basant sur l'algorithme EM.

6. APPROCHE DE SEGMENTATION AVEC APPLICATION DE L'ALGORITHME EM

Dans cette partie, on adopte un dénombrement simple des sites de la maille L en assignant le nombre $t=j+N1x(i-1)$ au site (i,j) . Cette classification dénombre les sites ligne par ligne de 1 à $n=N1xN2$, en commençant par le site $(1,1)$. De cette manière, l'image observée sera représentée par un vecteur de n composants, $y=\{y_1, y_2, \dots, y_n\}$ et similairement l'image régions, $x=\{x_1, x_2, \dots, x_n\}$. Dans ce cas les x_i sont des vecteurs unitaires de K composants, indiquant la classe d'appartenance du site i . Si x_i est attribué à la classe k alors on écrit $x_i=e_k$ où e_k est le vecteur unitaire dont le $k^{\text{ième}}$ composant est

égal à 1. On peut alors formuler le problème de la segmentation non supervisée en utilisant l'algorithme EM de la manière suivante.

6.1. L'étape E : Calcul de l'espérance conditionnelle

Calculer l'espérance conditionnelle $Q(\Phi/\hat{\Phi}^{(n)})$ pour le modèle statistique choisi. On a $P(W/\Phi)=P(Y/X, \Phi_Y)P(X/\Phi_x)$ où Φ_Y est le vecteur de paramètres attaché au modèle des données et Φ_x est celui du modèle des régions(i.e. $\Phi=(\Phi_y, \Phi_x)$), Donc :

$$\log(P(W/\Phi)) = \log[P(Y/X, \Phi_y)] + \log[P(X/\Phi_x)] \quad (\text{V.30})$$

Si les échantillons du champ Y sont indépendants alors $P(Y/X, \Phi_y)$ peut s'écrire :

$$P(Y/X, \Phi_y) = \prod_{i=1}^n P(Y_i = y_i / X_i = x_i, \Phi_y) \quad (\text{V.31})$$

Pour une implémentation efficace de l'algorithme de segmentation non supervisée on va utiliser l'approximation de la pseudo-vraisemblance concernant la distribution du champ de régions $P(X/\Phi_x)$ [BES-89] :

$$P(X/\Phi_x) \approx \prod_{i=1}^n P(X_i = x_i / X_j = x_j, j \in \eta_i, \Phi_x) \quad (\text{V.32})$$

Où η_i est le voisinage immédiat du site i dans la présente la maille L .

Cela signifie que la distribution jointe X est égale au produit des distributions conditionnelles locales $P(X_i = x_i / X_j = x_j, j \in \eta_i, \Phi_x)$.

Ainsi (V.30) aura la forme suivante:

$$\begin{aligned} \log(P(W/\Phi)) &= \sum_{i=1}^n \log[P(Y_i = y_i / X_i = x_i, \Phi_y)] \\ &+ \sum_{i=1}^n \log[P(X_i = x_i / X_j = x_j, j \in \eta_i, \Phi_x)] \end{aligned} \quad (\text{V.33})$$

Puisque x_i est un vecteur dont les composantes sont toutes nulles sauf une composante(i.e. $x_i=[0,0,\dots,1,0,\dots,0]^T$) donc on aura:

$$\log[P(Y_i = y_i / X_i = x_i, \Phi_y)] = x_i^T U(y_i / \Phi_y) \quad (\text{V.34})$$

ainsi que

$$\log[P(X_i = x_i / X_j = x_j, j \in \eta_i, \Phi_x)] = x_i^T V(\eta_i, \Phi_x) \quad (\text{V.35})$$

Où

$$U(y_i / \Phi_y) = [\log[P(y_i / e_1, \Phi_y)], \dots, \log[P(y_i / e_G, \Phi_y)]]^T \quad (V.36)$$

et

$$V(\eta_i, \Phi_x) = [\log[P(e_1 / x_j, j \in \eta_i, \Phi_x)], \dots, \log[P(e_G / x_j, j \in \eta_i, \Phi_x)]]^T \quad (V.37)$$

Par conséquent, l'expression de la fonction $Q(\Phi / \hat{\Phi}^{(p)})$ devient:

$$\begin{aligned} Q(\Phi / \hat{\Phi}^{(p)}) &= \sum_{i=1}^n E[x_i^T / Y, \hat{\Phi}^{(p)}] U(y_i / \Phi_y) \\ &+ \sum_{i=1}^n E[x_i^T / Y, \hat{\Phi}^{(p)}] V(\eta_i, \Phi_x) \end{aligned} \quad (V.38)$$

On peut montrer facilement que les composantes de l'espérance conditionnelle $E[x_i^T / Y, \hat{\Phi}^{(p)}]$ sont données par:

$$E[x_{ik} / Y, \hat{\Phi}^{(p)}] = \frac{\pi_k^{(p)} P(y_i / x_i = e_k, \hat{\Phi}_y^{(p)})}{\sum_{l=1}^G \pi_l^{(p)} P(y_i / x_i = e_l, \hat{\Phi}_y^{(p)})}; \quad k=1, 2, \dots, G \quad (V.39)$$

Où x_{ik} est la k ème composante du x_i et $\pi_k^{(p)}$ est donnée par:

$$\pi_k^{(p)} = P(x_i = e_k / x_j, j \in \eta_i, \hat{\Phi}_x^{(p)}) \quad (V.40)$$

On doit signaler que l'espérance conditionnelle donnée par (V.39) représente l'estimation quadratique moyenne de x_i^T [PAP-84], ainsi :

$$\hat{x}_i^T = E[x_i^T / Y, \hat{\Phi}^{(p)}] \quad (V.41)$$

\hat{x}_i^T est appelé l'estimée soft de x_i^T .

Si on suppose que $\hat{x}_j^{(p-1)}$ est l'estimateur de x_j à l'itération (p-1) alors l'estimée de $\pi_k^{(p)}$ sera:

$$\hat{\pi}_k^{(p)} = P(x_i = e_k / \hat{x}_j^{(p-1)}, j \in \eta_i, \hat{\Phi}_x^{(p)}) \quad (V.42)$$

6.2. L'étape M : Maximisation

Dans cette étape on cherche le vecteur $\hat{\Phi} = (\hat{\Phi}_y, \hat{\Phi}_x)$ des paramètres qui maximise la fonction $Q(\Phi/\hat{\Phi}^{(p)})$. La solution est obtenue donc, par l'annulation du gradient partiel de l'expression (V.38) par rapport à $\hat{\Phi}$. Ce qui permet d'avoir les équations suivantes :

$$\sum_{i=1}^n E[x_i^T / Y, \hat{\Phi}^{(p)}] \frac{\partial}{\partial \Phi_y} [U(y_i / \Phi_y)] = 0 \quad (\text{V.43})$$

et

$$\sum_{i=1}^n E[x_i^T / Y, \hat{\Phi}^{(p)}] \frac{\partial}{\partial \Phi_x} [V(\eta_i, \Phi_x)] = 0 \quad (\text{V.44})$$

Pour le modèle utilisé dans ce travail, les paramètres inconnus sont le vecteur $\Phi_y = [\sigma_1^2, \sigma_2^2, \dots, \sigma_G^2]^T$ caractérisant les distributions a priori $P(y_i / x_i = e_k, \hat{\Phi}_y^{(p)})_{k=1,2,\dots,G}$ et $\Phi_x = \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta$ caractérisant la distribution de Gibbs. Si on utilise pour les distributions a priori le modèle de l'image amplitude M-Look, c'est à dire:

$$P(y_i / x_i = e_k, \hat{\Phi}_y^{(p)}) = 2 \frac{y_i^{2M-1} e^{\frac{-y_i}{2\sigma_k^2/M}}}{(M-1)! \left(\frac{2\sigma_k^2}{M}\right)^M} \quad k=1,2,\dots,G \quad (\text{V.45})$$

Le remplacement dans l'équation (V.43), permettent d'estimer $\hat{\sigma}_k^{2(p+1)}$ pour $k=1,2,\dots,G$, soit :

$$\hat{\sigma}_k^{2(p+1)} = \frac{\sum_{i=1}^n E[x_{ik} / Y, \hat{\Phi}^{(p)}] y_i^2}{M \sum_{i=1}^n E[x_{ik} / Y, \hat{\Phi}^{(p)}]} \quad k=1,2,\dots,G. \quad (\text{V.46})$$

Du fait que X est un champ de Markov alors la distribution conditionnelle locale par rapport à une classe k est:

$$P(e_k / x_j, j \in \eta_i, \Phi_x) = \frac{e^{\beta \sum_{j \in \eta_i} v_{kj}}}{\sum_{k=1}^G e^{\beta \sum_{j \in \eta_i} v_{kj}}} \quad (\text{V.47})$$

où v_{kl} est donné par:

$$v_{kl} = \begin{cases} +1 & \text{si } \hat{x}_j^{(p-1)} = e_k \\ -1 & \text{si } \hat{x}_j^{(p-1)} \neq e_k \end{cases} \quad (\text{V.48})$$

Et η_i représente le vecteur de voisinage du site i donné par :

$$\eta_i = [u_1, u_2, u_3, u_4, v_1, v_2, v_3, v_4]^T \quad (\text{V.49})$$

où les voisinages u_i et v_i sont montrés à la figure (Fig. V.2)

En substituant (V.47) dans (V.44) et en effectuant la dérivation par rapport β , on obtient :

$$\sum_{i=1}^n \left[\sum_{k=1}^K \sum_{j \in \eta_i} E(x_{ik} / Y, \hat{\Phi}^{(p)}) v_{kj} \frac{\sum_{k=1}^G \sum_{j \in \eta_i} v_{kj} e^{\beta \sum_{j \in \eta_i} v_{kj}}}{\sum_{k=1}^G e^{\beta \sum_{j \in \eta_i} v_{kj}}} \right] = 0 \quad (\text{V.50})$$

Remarquant que cette équation est fortement non linéaire. Ainsi, sa résolution en $\hat{\beta}^{(p+1)}$ nécessite des méthodes numériques comme celle de Newton-Raphson. L'utilisation brute de (V.50) encombre beaucoup l'algorithme de segmentation non supervisée. A moins de trouver une forme plus adéquate de (V.50) pour le cas $G=2$ ou $G=3$. En fait, pour le cas $G=2$, on trouve :

$$U^{(p)} + 8c_1^{(p)} \text{tgh}(8\beta) + 6c_2^{(p)} \text{tgh}(6\beta) + 4c_3^{(p)} \text{tgh}(4\beta) + 2c_4^{(p)} \text{tgh}(2\beta) = 0 \quad (\text{V.51})$$

avec tgh est la tangente hyperbolique et $U^{(p)}$ est donné par:

$$U^{(p)} = \sum_{i=1}^n \sum_{k=1}^G \sum_{j \in \eta_i} E(x_{ik} / Y, \hat{\Phi}^{(p)}) v_{kj} \quad (\text{V.52})$$

et $c_i^{(p)}$ sont des constantes données par:

$$\begin{aligned} c_1^{(p)} &= \text{card} \left\{ \eta_i, i = \overline{1:n} : \text{abs} \left(\sum_{j \in \eta_i} v_{kj} \right) = 8, \text{ pour } k \in \Lambda \right\} \\ c_2^{(p)} &= \text{card} \left\{ \eta_i, i = \overline{1:n} : \text{abs} \left(\sum_{j \in \eta_i} v_{kj} \right) = 6, \text{ pour } k \in \Lambda \right\} \\ c_3^{(p)} &= \text{card} \left\{ \eta_i, i = \overline{1:n} : \text{abs} \left(\sum_{j \in \eta_i} v_{kj} \right) = 4, \text{ pour } k \in \Lambda \right\} \\ c_4^{(p)} &= \text{card} \left\{ \eta_i, i = \overline{1:n} : \text{abs} \left(\sum_{j \in \eta_i} v_{kj} \right) = 2, \text{ pour } k \in \Lambda \right\} \end{aligned} \quad (\text{V.53})$$

et pour le cas $K=3$ on aboutit à l'équation suivante:

$$U^{(p)} - [c_1^{(p)} f_1(\beta) + c_2^{(p)} f_2(\beta) + c_3^{(p)} f_3(\beta) - c_4^{(p)} f_4(\beta) + c_5^{(p)} f_5(\beta) + c_6^{(p)} f_6(\beta) + c_7^{(p)} f_7(\beta)] = 0 \quad (\text{V.54})$$

Avec les constantes $c_i^{(p)}$ et les fonctions f_i sont données en annexe C.

Pour $K > 3$ le nombre des constantes $c_i^{(p)}$ et des fonctions f_i augmente. Par conséquent l'implémentation de l'algorithme devient difficile. Dans ce cas, il est montré que les résultats de segmentation sont insensibles pour certain intervalle de β [DER-88] [ZHA-94]. Ainsi, la valeur adéquate de β peut être choisie à la base de la règle essai et erreur.

6.3. Segmentation

Dans cette étape, on cherche à assigner à chaque pixel ou site une étiquette. On remarque que l'étape E de l'algorithme EM, voir (32), fournit à l'itération p , l'estimateur soft $\tilde{x}_i^{(p)} = E(x_i / Y, \hat{\Phi}^{(p)}) = [\hat{x}_{i1}^{(p)}, \hat{x}_{i2}^{(p)}, \dots, \hat{x}_{iG}^{(p)}]^T$ de x_i ; le vecteur indicateur de la classe d'appartenance au site i . Les éléments $\hat{x}_{ik}^{(p)}$ sont compris dans l'intervalle $[0, 1]$ et ne sont pas forcément égale à 0 ou 1. Par conséquent, on utilise l'estimée hard qui correspond à l'élément maximum de $\hat{x}_i^{(p)}$. En d'autre termes, la classe affectée au site i correspond à l'élément maximale de $\hat{x}_i^{(p)}$. L'estimée hard est alors donné par :

$$\tilde{x}_i^{(p)} = \arg \max_k \hat{x}_{ik}^{(p)} \quad k = 1, 2, \dots, G. \quad (V.55)$$

D'après l'expression de $\hat{x}_{ik}^{(p)}$ (30), on déduit que cette dernière opération représente la segmentation au sens de l'estimateur MAP. Plus précisément :

$$\tilde{x}_i^{(p)} = \arg \max_k \hat{\pi}_k^{(p)} P(y_i / x_i = k, \hat{\Phi}_y^{(p)}) \quad k = 1, 2, \dots, G. \quad (V.56)$$

Ici, on utilise pour $\hat{\pi}_k^{(p)}$ l'expression suivante:

$$\hat{\pi}_k^{(p)} = P(x_i = k / \tilde{x}_j^{(p-1)}, j \in \eta_i, \hat{\Phi}_x^{(p)}) \quad (V.57)$$

Où $\tilde{x}_j^{(p-1)}$ est l'estimateur hard obtenu à l'itération $(p-1)$.

De ce fait cette stratégie de segmentation ressemble à l'algorithme ICM vu dans le chapitre précédent sauf qu'ici chaque segmentation est suivie par l'estimation des paramètres du modèle de l'image.

Finalement, il faut noter que cette approche de segmentation nécessite une segmentation initiale $\tilde{x}_j^{(0)}$ qui peut être trouvée par la méthode de maximum de vraisemblance en supposant $\hat{\pi}_k^{(0)}$ équiprobables (i.e. $\hat{\pi}_k^{(0)} = 1/G$).

Le schéma block de cette approche non supervisée qui utilise l'algorithme EM est illustré à la figure (Fig.V.3).

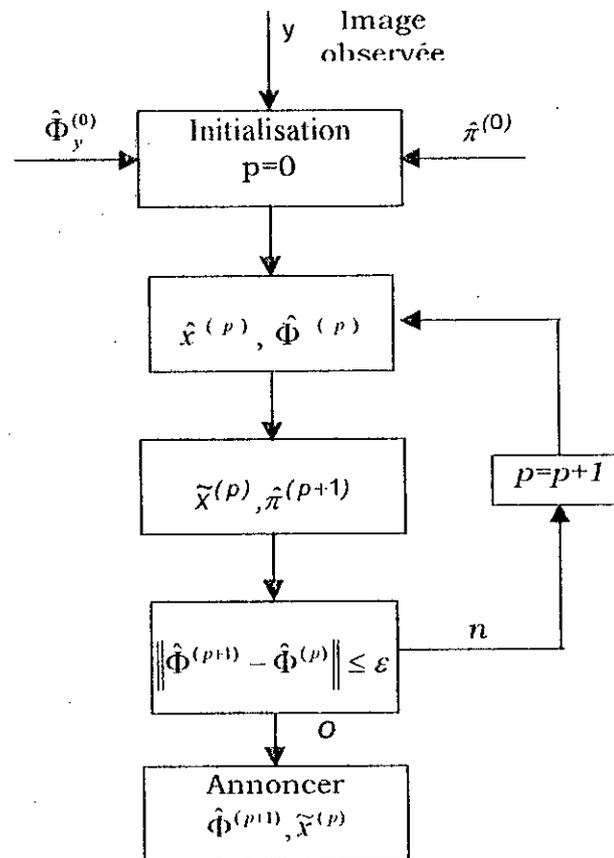


Fig. V.3 Algorithme de segmentation non supervisée

7. INITIALISATION DES ALGORITHMES DE SEGMENTATION NON SUPERVISEE

Les valeurs de paramètre initiales ont un impact significatif sur la rapidité de la convergence du procédé des algorithmes de segmentation non supervisée et sur la qualité des estimations finales. Dans notre application, nous employons la méthode suivante:

Le vecteur initial des paramètres $\hat{\Phi}_y^{(0)} = [\hat{\sigma}_1^{2(0)}, \hat{\sigma}_2^{2(0)}, \dots, \hat{\sigma}_G^{2(0)}]^T$ du modèle de bruit est déterminé en appliquant une fenêtres glissante non chevauchée et calculant ensuite le moment empirique d'ordre deux. Chaque estimation calculée sur la fenêtre glissante donne un échantillon $m_2^{(l)}$ du moment. Les échantillons prélevés $\{m_2^{(1)}, m_2^{(2)}, \dots, m_2^{(M)}\}$ sont ensuite groupés dans G classes par l'utilisation de l'algorithme K-moyennes de la façon suivante:

1. Choisir les centres initiaux $c_1^{(1)}, \dots, c_G^{(1)}$. Ceux-ci peuvent être arbitraires, mais sont habituellement définis par:

$$c_i^{[1]} = m_2^i \quad 1 \leq i \leq G \quad (\text{V.58})$$

2. À la $k^{\text{ème}}$ étape, assigner la valeur $m_2^{[l]}$, $1 \leq l \leq M$ au groupement j si

$$\|m_2^{[l]} - c_j^{[k]}\| \leq \|m_2^{[l]} - c_i^{[k]}\| \quad \text{pour tous } i \neq j \quad (\text{V.59})$$

Dans notre application, la mesure de similitude entre deux échantillons, $\|\bullet\|$, représente la distance euclidienne.

3. $C_j^{[k]}$ dénote le $j^{\text{ème}}$ groupement après l'étape 2 d'où les nouveaux centres de groupement :

$$c_j^{[k+1]} = \frac{1}{N_j} \sum_{m_2 \in C_j^{[k]}} m_2 \quad (\text{V.60})$$

Où N_j est le cardinal de $C_j^{[k]}$. Ainsi, le nouveau centre de groupement est la moyenne des échantillons des moments relatifs au groupement précédant.

4. répéter les étapes 2 et 3 jusqu'à ce qu'une convergence soit réalisée (i.e. $c_j^{[k+1]} = c_j^{[k]}$)

Pour commencer l'implémentation de ces algorithmes, les paramètres initiaux $\Phi_x^{[0]}$ de la distribution de Gibbs sont choisis dans l'intervalle $[0.1, 1.0]$. D'après les tests effectués, il est montré que les résultats obtenus ne sont pas sensibles à ce choix.

8. RESULTATS EXPERIMENTAUX

On présente dans cette section les résultats de segmentation obtenus par application des algorithmes recuit simulé adaptatif et l'algorithme décrit par la figure (Fig. V.3), ainsi nous avons testé les méthodes de pseudo-vraisemblance, LSQR et du codage pour l'estimation des paramètres du modèle de Gibbs.

8.1 Estimation des paramètres de Gibbs

Dans cette partie, on présente des exemples pour l'estimation des paramètres du modèle de Gibbs en utilisant des images de taille 128x128, qui sont générées par des valeurs

spécifiées des paramètres. La génération de ces images est faite par l'échantillonneur de Gibbs vu dans le chapitre précédent. Ces valeurs sont comparés avec les paramètres estimés par trois méthodes : pseudo- vraisemblance, LSQR et du codage. Les tests sont effectués sur des images ayant un modèle de Gibbs de premier et de second ordre. On a remarqué la technique la méthode LSQR nécessite un temps de calcul très élevé (plusieurs heures en utilisant le MATLAB) pour les images à plus de deux niveaux de gris. Pour cela, la comparaison de cette méthode avec les deux autres méthodes est faite seulement pour le cas des images à deux niveaux de gris. Les résultats obtenus ont montré l'efficacité des méthodes utilisées et surtout la méthode de codage.

Dans le tableau V.1, on présente les résultats numériques des exemples d'estimation de paramètres. Dans tous ces exemples, les réalisations sont celles d'un modèle de Gibbs premier ordre. Ainsi, on ne considère que les paramètres β_1 et β_2 .

Nombre de niveaux de gris	Paramètres exactes		Méthode LSQR		Méthode de maximum de pseudo vraisemblance		Méthode du codage	
	β_1	β_2	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_1$	$\hat{\beta}_2$
2	1,000	-1,000	1,019	-0,915	1,046	-0,912	1,066	-0,926
	1,000	1,000	0,964	0,972	0,922	0,997	0,926	1,002
	1,000	0,500	0,927	0,546	0,933	0,533	0,933	0,533
3	0,800	0,400			0,784	0,398	0,784	0,398
	2,000	2,000			1,679	1,664	1,682	1,669
4	1,500	1,500			1,490	1,353	1,490	1,366
	-0,600	-0,600			-0,659	-0,633	-0,659	-0,633

Tableau V.1. Résultats numériques pour les méthodes d'estimation (LSQR, pseudo vraisemblance, Codage) pour un système premier ordre.

On présente dans le tableau V.2, les résultats d'estimation de paramètres pour le cas du système second ordre. Ce qui revient à estimer les quatre paramètres β_1 , β_2 , β_3 et β_4 .

Nombre de niveaux de gris	2			4	
	Paramètres exactes	β_1	1,000	-1,000	1,000
β_2		1,000	1,000	1,000	0,300
β_3		-1,000	1,000	-0,500	0,300
β_4		-1,000	1,000	-0,500	0,300
Méthode LSQR	$\hat{\beta}_1$	0,929	-0,926		
	$\hat{\beta}_2$	0,959	0,916		
	$\hat{\beta}_3$	-0,917	0,873		
	$\hat{\beta}_4$	-0,950	0,945		
Méthode du maximum de pseudo vraisemblance	$\hat{\beta}_1$	1,022	-0,923	0,951	0,293
	$\hat{\beta}_2$	1,033	0,908	0,951	0,288
	$\hat{\beta}_3$	-1,028	0,942	-0,463	0,268
	$\hat{\beta}_4$	-0,912	1,054	-0,463	0,347
Méthode du codage	$\hat{\beta}_1$	1,049	-0,936	0,975	0,292
	$\hat{\beta}_2$	1,033	0,923	0,981	0,283
	$\hat{\beta}_3$	-1,029	0,966	-0,471	0,277
	$\hat{\beta}_4$	-0,984	1,072	-0,499	0,353

Tableau V.2. Résultats numériques pour les méthodes d'estimation (LSQR, pseudo vraisemblance, Codage) pour un système second ordre.

Les deux tableaux montrent que les résultats sont numériquement acceptables. En fait, dans le tableau V.1 l'erreur de l'estimation oscille entre 0,002 et 0,080 pour toutes les méthodes dans le cas des images binaires et entre 0,002 et 0,336 pour les méthodes de pseudo vraisemblance et du codage dans le cas des images de 3 et 4 niveaux de gris. Dans le tableau V.2 l'erreur de l'estimation varie entre 0,022 et 0,127 pour le cas des images binaires, et entre 0,001 et 0,077 pour le cas des images à 4 niveaux de gris.

L'un des facteurs qui pénalisent les estimations est le manque possible de convergence dans l'algorithme utilisant 50 itérations. Un autre facteur est l'insuffisance du nombre des échantillons utilisées pour l'estimation. En particulier, pour les images à plus de deux niveaux de gris.

8.2. Segmentation non supervisée des images SAR

L'efficacité de la stratégie est testée d'abord en utilisant des images synthétiques (image de Geman et Jain vues dans le chapitre IV) dont on connaît leurs segmentations. Ensuite, on applique cette technique sur des images radar réelles (de Laghouat et de Rome). Pour tous les tests, le vecteur initial des paramètres $\hat{\Phi}_y^{(0)} = [\hat{\sigma}_1^{2(0)}, \hat{\sigma}_2^{2(0)}, \dots, \hat{\sigma}_G^{2(0)}]^T$ est déterminé par la méthode décrite dans la section (V.7).

Les figures (Fig.V.5) à [Fig. V.8) montrent les résultats de segmentation de l'approche non supervisée par utilisation de l'algorithme EM et RSADAP (RS adaptatif) respectivement. On remarque que les résultats sont plus performants par rapport aux méthodes supervisées dans la mesure où les régions sont lisses et les frontières entre les différents régions plus franches.

Les résultats en pourcentage de l'erreur de classification sont donnés au tableau V.3 On remarque que l'algorithme EM donne une meilleure classification, dans le cas des images synthétiques, que le recuit simulé adaptatif. Ceci est dû au fait à la bonne initialisation de l'EM en utilisant l'estimateur de maximum de vraisemblance pour l'image d'étiquettes. On remarque d'un autre coté que le RS adaptatif est mieux que l'EM dans le cas où le bruit est intensif (image Rome). Ce qui favorise cet algorithme dans ces situations.

L'évolution du paramètre (β) estimé à chaque itération par L'algorithme EM, pour les quatre images est donnée à la figure (Fig. V.4) le temps de calcul qui correspond à la stabilité de β estimé par l'EM et ainsi que celui de RSADAP est donné au tableau V.4.

IMAGE \ ALGORITHME	Geman	Jain
EM	2,53%	5,45%
RSADAP	4.95%	7,33%

Tableau V.3. Erreur de classification.

IMAGE \ ALGORITHME	Geman	Jain	Lagouat	Rome
EM	1 m 57,93 s	1 m 57,26 s	33,56 s	1 m 7,51 s
RSADAP	3 m 33,17 s			

Tableau V.4. Temps de calcul des différents algorithmes

9. CONCLUSION

Dans ce chapitre, nous avons testé les algorithmes de segmentation non supervisée proposés sur des images synthétiques specklées et réelles. Les algorithmes ont été mis en œuvre sur un PC AMD de fréquence d'horloge 450 MHz et 32MO de RAM.

Nous avons comparé les paramètres et les résultats obtenus aux résultats supervisés présentés dans le Chapitre IV. En général, la qualité des résultats non supervisés est meilleure que ceux des algorithmes supervisés. Cependant, nous avons observé que les algorithmes non supervisés sont plus sensibles au bruit à cause de l'initialisation des paramètres et l'image étiquette.

Généralement, la qualité du traitement et le temps de calcul dépendent de l'image à traiter. Les méthodes de segmentation que nous avons étudié dans ce chapitre sont semi-automatiques dont la mesure où ils nécessitent la connaissance du nombre des classes.

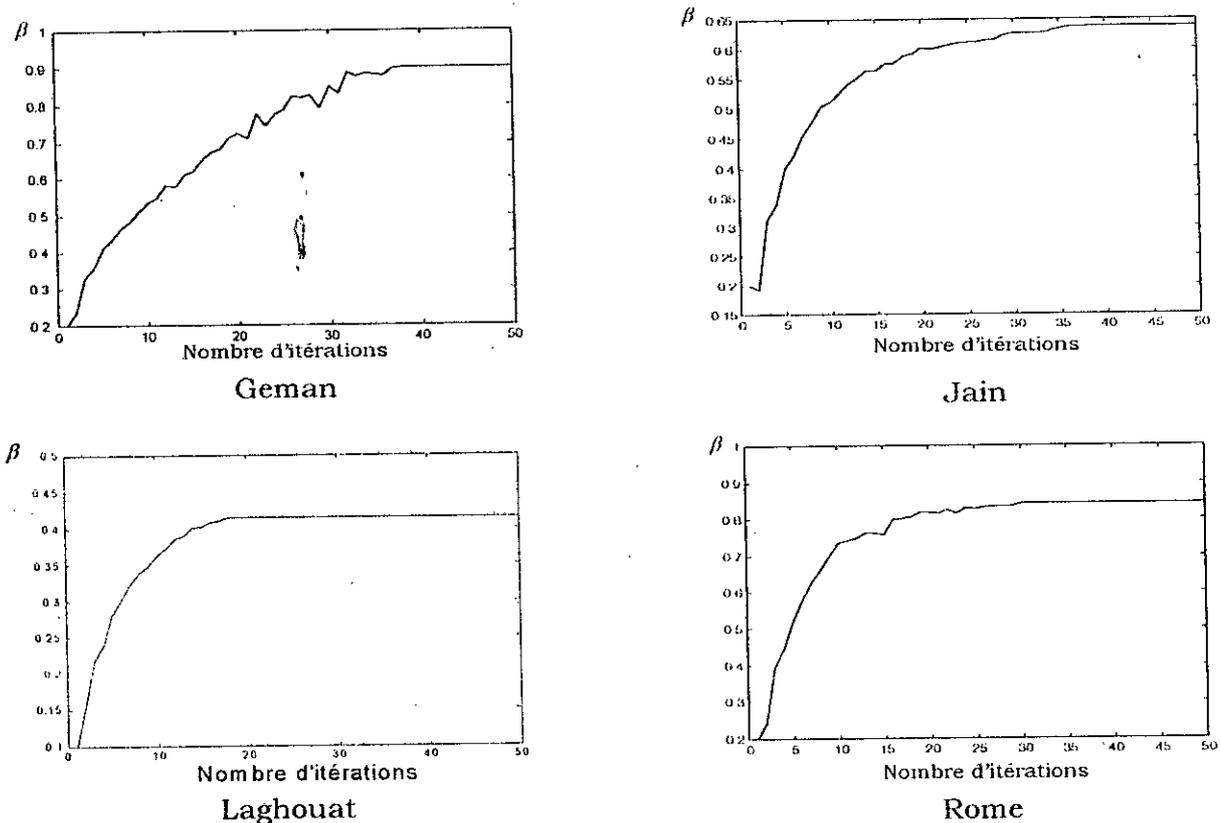
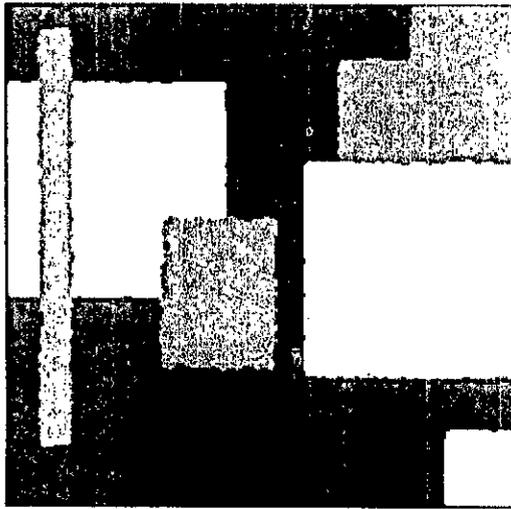
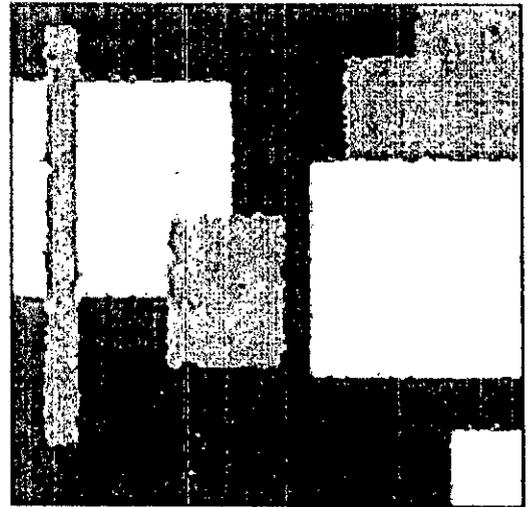


Fig. V.4 Evolution de β après exécution de l'EM

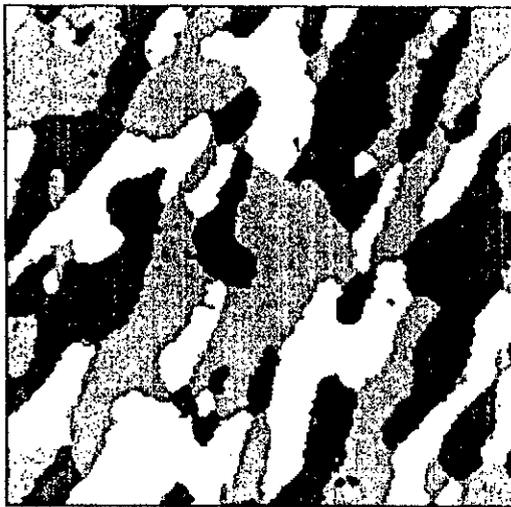


EM

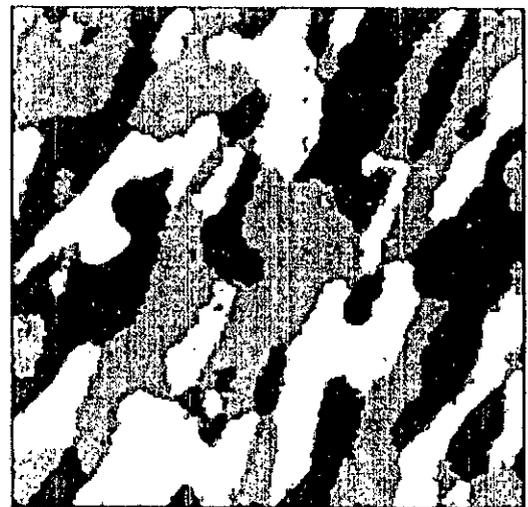


RSADAP

Fig. V.5 Résultat avec l'image Geman

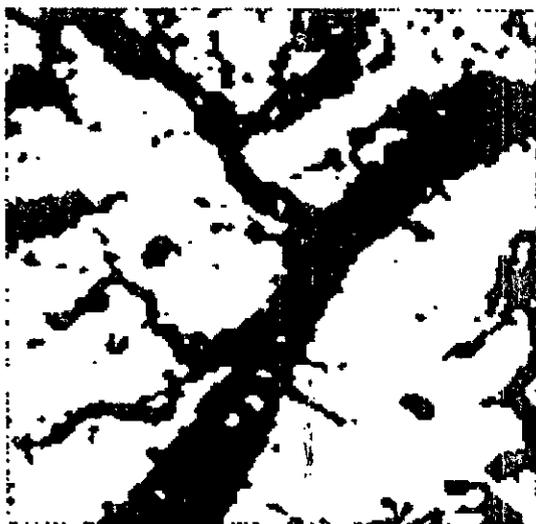


EM

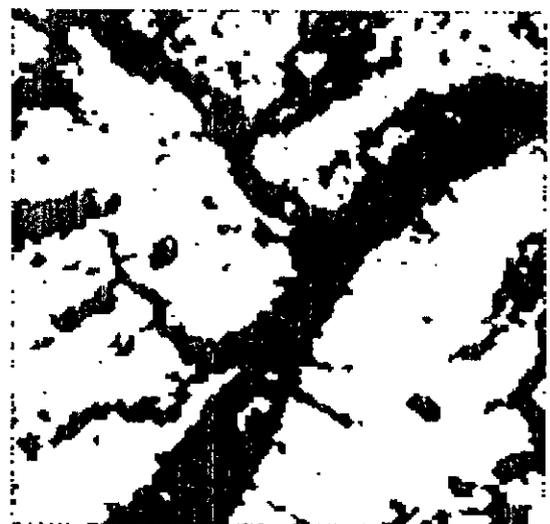


RSADAP

Fig. V.6 Résultat avec l'image Jain

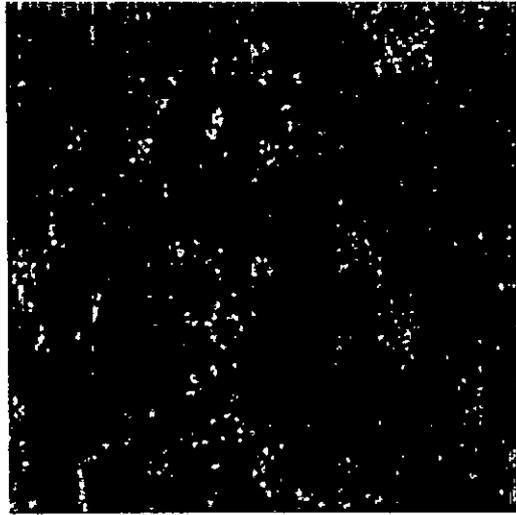


EM

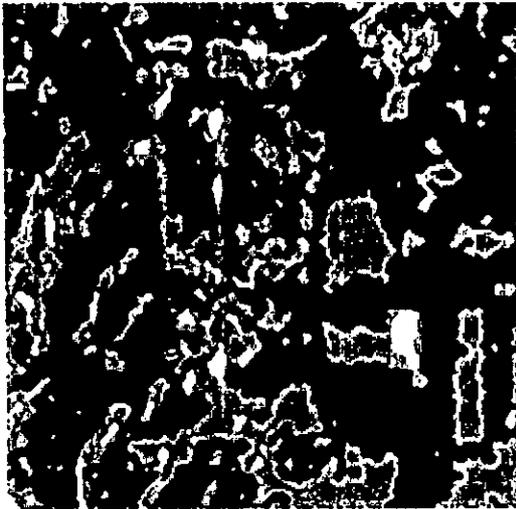


RSADAP

Fig. V.7 Résultat avec l'image radar de Laghouat



original



EM



RSADAP

Fig. V.8 Résultat avec l'image radar de Rome

CONCLUSION GENERALE

DANS cette thèse, notre principale contribution a été le développement d'une approche de segmentation en régions des images SAR. Cette dernière est fondée sur l'approche bayésienne en utilisant des champs de Markov, et procédée en trois étapes : la modélisation, l'optimisation et l'estimation.

La multitude des méthodes de segmentation présentées dans la littérature témoigne du fait que la segmentation est un processus compliqué et fragile. Il n'y a pas de solution miracle applicable automatiquement à toutes les situations. De plus, l'aspect du speckle des images SAR et son caractère non-quantifiable rendent plus complexe la tâche de segmentation.

Nous avons constaté que c'était un problème mal-posé. En ce sens, l'existence, l'unicité et la stabilité de la solution ne peuvent être garanties en l'absence de contraintes additionnelles, la théorie de la régularisation permet de reformuler et mieux poser ce dernier problème, en imposant au type de la solution certaines hypothèses a priori. Notre modélisation Markovienne se trouve alors appropriée, elle nous a permis d'incorporer des contraintes spécifiques dans des fonctions de potentiel. Finalement, notre problème se réduit à la minimisation d'une expression appelée fonction d'énergie.

Après avoir présenté le modèle de segmentation de l'image, on a implémenté des méthodes de segmentation supervisée, en utilisant successivement les algorithmes d'optimisation aléatoires et déterministes pour minimiser la fonction d'énergie :

- ◆ Les algorithmes aléatoires à base de recuit simulé dont nous avons implémenté une variante, assurent la convergence vers l'optimum global du critère (théoriquement), mais sont très coûteux en temps de calcul.
- ◆ Les algorithmes déterministes desquels on a implémenté la méthode ICM (Iterative Conditional Modes) et la méthode MMD (Modified Metropolis Dynamic), s'exécutent en des temps très courts mais risquent de converger vers un minimum local, donc la qualité des résultats dépend fortement de l'initialisation.

Les résultats des méthodes supervisées sont sensibles aux valeurs des paramètres utilisés dans le modèle de segmentation. Par conséquent, leur estimation est recommandée. Cependant, cette estimation nécessite une segmentation de l'image. ce

cercle vicieux nous oblige à utiliser les méthodes de segmentation non supervisées qui sont implémentées dans la deuxième étape où nous avons testé les performances des algorithmes EM (Expectation Maximisation) et recuit simulé adaptatif sur des images synthétiques et réelles. Nous avons vu que les résultats obtenus sont meilleurs par rapport à ceux des méthodes non supervisées

Les résultats encourageants que nous avons obtenus restent néanmoins perfectibles. Nous pouvons envisager quelques perspectives d'extension :

- ♦ Implémenter les algorithmes de segmentation sur une architecture parallèle afin de remédier au problème du temps de calcul [SZI-97].
- ♦ Utiliser l'analyse en multirésolution dans le but d'éviter la convergence vers un minimum local pour le cas des algorithmes déterministes [KAT-94].
- ♦ Utiliser d'autres méthodes fondées sur les réseaux de neurones et la logique floue, qui ne nécessitent pas de méthodes de calcul rigoureuses [NGU-93], et dont l'estimation des paramètres, du nombre de classes et la segmentation sont déterminés automatiquement (méthodes dites « aveugles »).

ANNEXE A

Résolution d'un système d'équations non linéaires

On s'intéresse ici à la résolution du système d'équations suivants :

$$\begin{cases} f_1(x_1, x_2, \dots, x_n) \\ f_2(x_1, x_2, \dots, x_n) \\ \dots \\ f_n(x_1, x_2, \dots, x_n) \end{cases} \quad (\text{A.1})$$

où les f_i sont des fonctions non linéaires des variables x_1, x_2, \dots, x_n .

Notons $X^* = [x_1^*, x_2^*, \dots, x_n^*]^T$ le vecteur solution du système non linéaire (A.1).

Si chaque fonction f_i est continue et continûment différentiable, alors par développement en série de Taylor dans le voisinage d'un estimé $X^{(k)}$ proche de X^* (obtenu à la $k^{\text{ème}}$ itération) on obtient :

$$\begin{aligned} f_i(X^*) &= f_i(X^{(k)} + (X^* - X^{(k)})) = f_i(X^{(k)}) + \sum_{j=1}^n \frac{\partial f_i(X^{(k)})}{\partial x_j} (x_j^* - x_j^{(k)}) \\ &+ \frac{1}{2!} \sum_{j=1}^n \sum_{r=1}^n \frac{\partial^2 f_i(X^{(k)})}{\partial x_j \partial x_r} (x_j^* - x_j^{(k)})(x_r^* - x_r^{(k)}) + \dots \end{aligned} \quad (\text{A.2})$$

pour $i=1, 2, \dots, n$.

si $X^{(k)}$ est un estimé proche de X^* , les éléments $(x_i^* - x_i^{(k)})^2$ sont négligeables, ainsi que les termes de degré supérieur. Le système (A.2) s'écrit donc

$$\sum_{j=1}^n \frac{\partial f_i(X^{(k)})}{\partial x_j} (x_j^* - x_j^{(k)}) = -f_i(X^{(k)}) \quad (\text{A.3})$$

définissons la matrice $E^{(k)}$ des dérivées premières telles que

$$E_{ij}^{(k)} = \frac{\partial f_i(X^{(k)})}{\partial x_j} \quad (\text{A.4})$$

les éléments du vecteur d'erreur $\Delta X^{(k)}$ par :

$$\Delta x_j^{(k)} = x_j^* - x_j^{(k)} \quad (\text{A.5})$$

puis les éléments du vecteur $F^{(k)}$ par :

$$F_i^{(k)} = -f_i(X^{(k)}) \quad (\text{A.6})$$

alors la relation matricielle (A.3) s'écrit :

$$E^{(k)} \Delta X^{(k)} = -f_i(X^{(k)}) \quad (\text{A.7})$$

Dans l'équation (A.7), toutes les quantités sont connues hormis les $\Delta X^{(k)}$. cette équation est un système linéaire, les méthodes classiques de résolution des systèmes linéaires tels que la méthode de Gauss, de Jordan, de Cholevsky et de Jacobi sont appliqués pour déterminer les ΔX .

$\Delta X^{(k)}$ est un estimé de l'erreur commise en approximant X^* par $X^{(k)}$. D'après la méthode de Newton, le meilleur estimé $X^{(k+1)}$ de X^* est donné par :

$$X^{(k+1)} = X^{(k)} + \lambda \Delta X^{(k)} \quad (\text{A.8})$$

où $\Delta X^{(k)}$ est la solution de (A.7) et λ est un facteur d'amortissement tel que $0 < \lambda \leq 1$. Lorsque $\lambda=1$ on obtient la méthode de Newton classique dans le cas où $\lambda < 1$ la méthode de newton dite amortie.

On continue la mise à jour de (A.8) jusqu'à ce qu'on ait :

$$\|X^{(k+1)} - X^{(k)}\| < \varepsilon \quad (\text{A.9})$$

où ε est un seuil fixé a priori.

ANNEXE B

Modèle adapté aux discontinuités

Comme notre objectif est d'obtenir une image en régions lisses séparées par des bords francs, ce modèle est adapté à ce genre de problèmes. Dans ce cas, l'image segmentée est obtenue en minimisant la fonction d'énergie :

$$E_{glob} = U_1(Y, X) + U_2(B) + U_3(X) \quad (B.1)$$

Où Y représente l'image amplitude observée, X est l'image étiquettes et B est le vecteur de bruit distribué selon la loi Gamma.

♦ Le terme $U_1(X/Y)$ est le terme attache aux. il mesure le désaccord entre le modèle de bruit supposé et les données réellement acquises Y . Or le speckle B est un bruit multiplicatif :

$$Y = X_d B = B_d X \quad (B.2)$$

où $X_d = \text{diag}(X)$ and $B_d = \text{diag}(B)$

alors :

$$U_1(Y/X) = \|Y - B_d X\|^2 = \|Y - X_d B\|^2 \quad (B.3)$$

♦ Le terme $U_2(B)$ est le logarithme de la distribution jointe des échantillons de bruit :

$$U_2(B) = -\ln[p(B)] = -\sum K \frac{b_i^{2L-1}}{\sigma^{2L}} \exp\left[-\frac{b_i^2}{2\sigma^2}\right] \quad (B.4)$$

$$\text{où } K = \frac{1}{2^{L-1} \Gamma(L)}$$

♦ Le terme $U_3(X)$ est le terme de régularisation. Il mesure l'irrégularité de la solution donnée pour un système de voisinage d'ordre deux dont on utilise que les cliques pairs par [LI-96] :

$$U_3(X) = \beta \sum_{n=1, j}^N \left[\varphi(D_x x_{i,j}) + \varphi(D_y x_{i,j}) + \varphi(D_d x_{i,j}) + \varphi(D_{d^*} x_{i,j}) \right] \quad (B.5)$$

la fonction φ , représente la pénalité concernant l'irrégularité dans le gradient. Où $D_{direction}$ représente l'opérateur différentiel d'ordre 1 dans les quatre sens (horizontal, vertical, diagonal et antidiagonal). Nous avons donc :

$$\begin{cases} D_x x_{i,j} = \frac{x_{i,j} - x_{i,j-1}}{\delta} \\ D_y x_{i,j} = \frac{x_{i,j} - x_{i-1,j}}{\delta} \\ D_d x_{i,j} = \frac{x_{i,j} - x_{i-1,j-1}}{\delta\sqrt{2}} \\ D_{d'} x_{i,j} = \frac{x_{i,j} - x_{i+1,j-1}}{\delta\sqrt{2}} \end{cases} \quad (\text{B.6})$$

Généralement on n'utilise que la composante horizontale et verticale (le système de premier ordre).

Pour B fixé, La fonction X^* qui minimise E_{glob} vérifie l'équation normale suivante [MAT-97] :

$$\left(B_d' B_d + \frac{\lambda^2}{\delta^2} \Delta_{pond} \right) X = B_d' Y \quad (\text{B.7})$$

où Δ_{pond} est une approximation discrète d'un laplacien pondéré. Au site (i,j) , les coefficients sont donnés par :

$$\Delta_{pond} = \begin{pmatrix} 0 & \lambda^N & 0 \\ \lambda^W & 0 & \lambda^E \\ 0 & \lambda^S & 0 \end{pmatrix} \quad (\text{B.8})$$

les poids sont définis comme suit :

$$\begin{aligned} \lambda^W &= \frac{\varphi'(x_{i,j-1} - x_{i,j})}{2|x_{i,j-1} - x_{i,j}|} & \lambda^E &= \frac{\varphi'(x_{i,j+1} - x_{i,j})}{2|x_{i,j+1} - x_{i,j}|} \\ \lambda^S &= \frac{\varphi'(x_{i+1,j} - x_{i,j})}{2|x_{i+1,j} - x_{i,j}|} & \lambda^N &= \frac{\varphi'(x_{i-1,j} - x_{i,j})}{2|x_{i-1,j} - x_{i,j}|} \end{aligned} \quad (\text{B.9})$$

la fonction $h(u) = \frac{\varphi'(u)}{2|u|}$ qui définit les poids du laplacien est appelée fonction d'interaction [LI-96] (elle détermine le taux d'interaction entre deux pixels voisins). L'objectif du

modèle adapté aux discontinuités est de lisser les régions homogènes de l'image, préserver les discontinuités de lissage, et de casser le lien entre les pixels voisins proportionnellement à la valeur du gradient. Ainsi, la fonction d'interaction doit vérifier les conditions suivantes :

1. $\lim_{u \rightarrow 0} h(u) = 1$
2. $\lim_{u \rightarrow \infty} h(u) = 0$
3. $h(u)$ doit être continue et strictement décroissante sur $[0, +\infty[$

Parmi les fonctions (h, φ) qui vérifient ces conditions on trouve :

NOM	h	φ
Fonction exponentielle	$\exp(-u^2)$	$-\exp(-u^2)$
Fonction de Geman-McClure	$\frac{1}{(1+u^2)^2}$	$\frac{u^2}{1+u^2}$
Fonction de Herbert et Leahy	$\frac{1}{1+u^2}$	$\ln(1+u^2)$
Fonction hyperbolique	$\frac{1}{1+ u }$	$2(u + \ln(1+ u))$

Tableau B.1. Fonctions d'interactions

ANNEXE C

Calcul du gradient pour l'estimation des paramètres

L'estimation des paramètres de Gibbs dans le cas la méthode du codage nécessitera l'annulation du Gradient dans un domaine D_n de l'expression (voir chapitre V) :

$$L(\Phi_x) = \sum_{s \in D_n} \log \left(\frac{\exp(-\Theta^T(s, \eta_s) \cdot \Phi_x)}{\sum_{g \in \Lambda} \exp(-\Theta^T(g, \eta_s) \cdot \Phi_x)} \right) \quad (C.1)$$

en annulant le gradient on obtient :

$$\frac{\partial L(\Phi_x)}{\partial \Phi_x(i)} = - \sum_{s \in D_n} \Theta^T(s, \eta_s) \cdot e_i + \sum_{s \in D_n} \frac{\sum_{g=0}^{G-1} \Theta^T(g, \eta_s) \cdot e_i \cdot \exp(-\Theta^T(g, \eta_s) \cdot \Phi_x)}{\sum_{g=0}^{G-1} \exp(-\Theta^T(g, \eta_s) \cdot \Phi_x)} = 0 \quad (C.2)$$

pour $i=1, 2, \dots, N_b$,

où N_b est le nombre de paramètres et e_i ($e_i = [0, 0, \dots, 1, 0, \dots, 0]^T$) est un vecteur unitaire de N_b éléments avec la $i^{\text{ème}}$ composante égale à l'unité.

La résolution de ce système est réalisée par la méthode de Newton décrite dans l'annexe A). Quoique son implémentation soit difficile

On distingue deux cas, selon qu'on travaille avec un système de premier ou de deuxième ordre.

Cas d'un système de premier ordre

On considère ici que les cliques pairs horizontaux et verticaux. Dans ce système on a ($N_b=2$) :

$$\Phi_x = [\beta_1, \beta_2]^T \quad (C.3)$$

et

$$\Theta(s, \eta_s) = [(I(s, u_1) + I(s, u_3)), (I(s, u_2) + I(s, u_4))] \quad (C.4)$$

avec u_1, u_2, u_3 et u_4 sont donnés à la Fig.V.2.

L'utilisation directe de (C.2) encombre beaucoup les algorithmes de segmentation non supervisée qui nécessitent l'estimation des paramètre de Gibbs. Afin de trouver une forme plus adéquate de (C.2), on étudie toutes les configurations des types de cliques d'un système de premier ordre, et par la suite, on trouve le système à deux équations suivant :

$$\begin{aligned} U_1 - 2.[c_1.f_1 + c_2.f_2 + c_3.f_3 + c_4.f_4 + c_5.f_5 + c_6.f_6 + c_7.f_7 + c_8.f_8 + c_9.f_9] &= 0 \\ U_2 - 2.[c_1.g_1 + c_2.g_2 + c_3.g_3 + c_4.g_4 + c_5.g_5 + c_6.g_6 + c_7.g_7 + c_8.g_8 + c_9.g_9] &= 0 \end{aligned} \quad (C.5)$$

où U_1 et U_2 sont données par :

$$\begin{aligned}
 U_1 &= \sum_{s \in D_n} \Theta^T(s, \eta_s) \cdot e_1 \\
 U_2 &= \sum_{s \in D_n} \Theta^T(s, \eta_s) \cdot e_2
 \end{aligned}
 \tag{C.6}$$

et avec les fonctions f_i et g_i sont données comme suit :

$$\begin{aligned}
 f_1(\beta_1, \beta_2) &= \frac{-\exp(2.\text{sb}) + (G - 1).\exp(-2.\text{sb})}{\exp(2.\text{sb}) + (G - 1).\exp(-2.\text{sb})} \\
 f_2(\beta_1, \beta_2) &= \frac{(G - 2).\exp(-2.\text{sb})}{\exp(2.\beta_2) + \exp(-2.\beta_2) + (G - 2).\exp(-2.\text{sb})} \\
 f_3(\beta_1, \beta_2) &= \frac{\exp(-2.\text{db}) - \exp(2.\text{db}) + (G - 2).\exp(-2.\text{sb})}{\exp(-2.\text{db}) + \exp(2.\text{db}) + (G - 2).\exp(-2.\text{sb})} \\
 f_4(\beta_1, \beta_2) &= \frac{(G - 2).\exp(-2.\text{sb})}{2 + (G - 2).\exp(-2.\text{sb})} \\
 f_5(\beta_1, \beta_2) &= \frac{-\exp(2.\beta_1) + \exp(-2.\beta_1) + (G - 2).\exp(-2.\text{sb})}{(\exp(2.\beta_1) + \exp(-2.\beta_1) + (G - 2).\exp(-2.\text{sb}))} \\
 f_6(\beta_1, \beta_2) &= \frac{\exp(-2.\text{db}) + (G - 3).\exp(-2.\text{sb})}{\exp(-2.\text{db}) + 2.\exp(-2.\beta_2) + (G - 3).\exp(-2.\text{sb})} \\
 f_7(\beta_1, \beta_2) &= \frac{\exp(-2.\beta_1) + (G - 3).\exp(-2.\text{sb})}{1 + \exp(-2.\beta_1) + \exp(-2.\beta_2) + (G - 3).\exp(-2.\text{sb})} \\
 f_8(\beta_1, \beta_2) &= \frac{2.\exp(-2.\beta_1) - \exp(2.\text{db}) + (G - 3).\exp(-2.\text{sb})}{2.\exp(-2.\beta_1) + \exp(2.\text{db}) + (G - 3).\exp(-2.\text{sb})} \\
 f_9(\beta_1, \beta_2) &= \frac{2.\exp(-2.\beta_1) + (G - 4).\exp(-2.\text{sb})}{2.\exp(-2.\beta_1) + 2.\exp(-2.\beta_2) + (G - 4).\exp(-2.\text{sb})} \\
 g_1(\beta_1, \beta_2) &= f_1 \\
 g_2(\beta_1, \beta_2) &= \frac{-\exp(2.\beta_2) + \exp(-2.\beta_2) + (G - 2).\exp(-2.\text{sb})}{\exp(2.\beta_2) + \exp(-2.\beta_2) + (G - 2).\exp(-2.\text{sb})} \\
 g_3(\beta_1, \beta_2) &= \frac{-\exp(-2.\text{db}) + \exp(2.\text{db}) + (G - 2).\exp(-2.\text{sb})}{\exp(-2.\text{db}) + \exp(2.\text{db}) + (G - 2).\exp(-2.\text{sb})} \\
 g_4(\beta_1, \beta_2) &= \frac{(G - 2).\exp(-2.\text{sb})}{2 + (G - 2).\exp(-2.\text{sb})} \\
 g_5(\beta_1, \beta_2) &= \frac{(G - 2).\exp(-2.\text{sb})}{\exp(2.\beta_1) + \exp(-2.\beta_1) + (G - 2).\exp(-2.\text{sb})}
 \end{aligned}$$

$$\begin{aligned}
g_6(\beta_1, \beta_2) &= \frac{-\exp(-2.db) + 2.\exp(-2.\beta_2) + (G-3).\exp(-2.sb)}{\exp(-2.db) + 2.\exp(-2.\beta_2) + (G-3).\exp(-2.sb)} \\
g_7(\beta_1, \beta_2) &= \frac{\exp(-2.\beta_2) + (G-3).\exp(-2.sb)}{1 + \exp(-2.\beta_1) + \exp(-2.\beta_2) + (G-3).\exp(-2.sb)} \\
g_8(\beta_1, \beta_2) &= \frac{\exp(2.db) + (G-3).\exp(-2.sb)}{2.\exp(-2.\beta_1) + \exp(2.db) + (G-3).\exp(-2.sb)} \\
g_9(\beta_1, \beta_2) &= \frac{2.\exp(-2.\beta_2) + (G-4).\exp(-2.sb)}{2.\exp(-2.\beta_1) + 2.\exp(-2.\beta_2) + (G-4).\exp(-2.sb)}
\end{aligned} \tag{C.7}$$

où $sb = \beta_1 + \beta_2$ et $db = \beta_1 - \beta_2$.

Les constantes c_i sont définies comme suit :

$$c_i = \text{card} \{ \eta_s, s \in D_n : h_1 = m_i \text{ et } h_3 = n_i \} \tag{C.8}$$

où h est un vecteur de G composantes dont les éléments sont triés par ordre décroissant. Sa $g^{\text{ème}}$ composante est définie par :

$$h_g = 1 - [\Theta^T(g, \eta_s).e_1] / 2 + 3. [1 - [\Theta^T(g, \eta_s).e_2] / 2] ; g \in A \tag{C.9}$$

et m_i et n_i sont donnés par le tableau suivant :

i	1	2	3	4	5	6	7	8	9
m_i	8	7	6	4	5	6	4	3	3
n_i	-	-	0	0	-	1	1	2	1

Tableau C.1. valeurs m_i et n_i ($\beta_1 \neq \beta_2$)

Il est à noter que m_i n'est pas considéré pour le cas de $G=2$.

Pour le cas d'une image à deux classes, on considère que les constantes c_1, c_2, c_3, c_4, c_5 , et pour le cas d'une image à trois classes, on considère toutes les constantes sauf c_9 .

Si on a $\beta_1 = \beta_2$ on obtient l'équation :

$$U.(c_1.f_1 + c_2.f_2 + c_3.f_3 + c_4.f_4 + c_5.f_5) = 0 \tag{C.10}$$

où U est donnée par :

$$U = \sum_{s \in D_n} \Theta^T(s, \eta_s).e \tag{C.11}$$

avec e est un vecteur de N_b composantes dont tous les éléments sont égaux à 1 ($e_i = [1, \dots, 1]^n$).

Les fonctions f_i sont exprimées par :

$$f_1(\beta) = \frac{-4.\exp(4.\beta) + 4.(G-1).\exp(-4.\beta)}{\exp(4.\beta) + (G-1).\exp(-4.\beta)}$$

$$\begin{aligned}
f_2(\beta) &= \frac{-2.\exp(2.\beta) + 2.\exp(-2.\beta) + 4.(G-2).\exp(-4.\beta)}{\exp(2.\beta) + \exp(-2.\beta) + (G-2).\exp(-4.\beta)} \\
f_3(\beta) &= \frac{4.(G-2).\exp(-4.\beta)}{2 + (G-2).\exp(-4.\beta)} \\
f_4(\beta) &= \frac{4.\exp(-2.\beta) + 4.(G-3).\exp(-4.\beta)}{1 + 2.\exp(-2.\beta) + (G-3).\exp(-4.\beta)} \\
f_5(\beta) &= \frac{8.\exp(-2.\beta) + 4.(G-4).\exp(-4.\beta)}{4.\exp(-2.\beta) + (G-4).\exp(-4.\beta)}
\end{aligned} \tag{C.12}$$

(pour $G=2$ on considère que f_1, f_2, f_3 et pour $G=3$ on ne considère que f_3).

et les constantes c_l sont définies comme suit :

$$c_l = \text{card} \{ \eta_s, s \in D_n : h_1 = m_l \text{ et } h_2 = n_l \} \tag{C.13}$$

ici h est défini comme suit :

$$h_g = 1 - [\Theta^T(g, \eta_s).e] / 2; \quad g \in \Lambda \tag{C.14}$$

et m_l et n_l sont données par :

l	1	2	3	4	5
m_l	4	3	2	2	1
n_l	-	-	0	1	1

Tableau C.2. valeurs m_l et n_l ($\beta_1 = \beta_2$)

Cas d'un système de second ordre

Pour ce système ($N_b=4$), le vecteur de paramètres à estimer est :

$$\Phi_x = [\beta_1, \beta_2, \beta_3, \beta_4]^T \tag{C.15}$$

et le vecteur des fonctions de potentiel est donné par :

$$\Theta(s, \eta_s) = \left[\left(I(s, u_1) + I(s, u_3) \right), \left(I(s, u_2) + I(s, u_4) \right) \right. \\
\left. \left(I(s, v_2) + I(s, v_4) \right), \left(I(s, v_1) + I(s, v_3) \right) \right] \tag{C.16}$$

dans le cas général, il est difficile de trouver une forme simplifiée de l'équation (C.2) pour ce système. Néanmoins, une expression dans le cas où ($\beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta$) et pour une image de deux et trois classes a été trouvée. La formule simplifiée pour le cas de l'image de deux classes est donnée par l'équation (V.51). pour le cas $G=3$ on obtient :

$$U - c_1 f_1(\beta) - c_2 f_2(\beta) - c_3 f_3(\beta) - c_4 f_4(\beta) - c_5 f_5(\beta) - c_6 f_6(\beta) - c_7 f_7(\beta) = 0$$

U est la même que (C.11).

avec :

$$\begin{aligned} f_1 &= \frac{8 \cdot (-\exp(8\beta) + 2 \cdot \exp(-8\beta))}{\exp(8\beta) + 2 \cdot \exp(-8\beta)} \\ f_2 &= \frac{-6 \cdot \exp(6\beta) + 6 \cdot \exp(-6\beta) + 8 \cdot \exp(-8\beta)}{\exp(6\beta) + \exp(-6\beta) + \exp(-8\beta)} \\ f_3 &= \frac{-4 \cdot \exp(4\beta) + 4 \cdot \exp(-4\beta) + 8 \cdot \exp(-8\beta)}{\exp(4\beta) + \exp(-4\beta) + \exp(-8\beta)} \\ f_4 &= \frac{-4 \cdot \exp(4\beta) + 12 \cdot \exp(-6\beta)}{\exp(4\beta) + 2 \cdot \exp(-6\beta)} \\ f_5 &= \frac{-2 \cdot \exp(2\beta) + 2 \cdot \exp(-2\beta) + 8 \cdot \exp(-8\beta)}{\exp(2\beta) + \exp(-2\beta) + \exp(-8\beta)} \\ f_6 &= \frac{-2 \cdot \exp(2\beta) + 4 \cdot \exp(-4\beta) + 6 \cdot \exp(-6\beta)}{\exp(2\beta) + \exp(-4\beta) + \exp(-6\beta)} \\ f_7 &= \frac{8 \cdot \exp(-4\beta)}{2 \cdot \exp(-4\beta) + 1} \end{aligned} \tag{C.17}$$

et les constantes c_l sont données par :

$$c_l = \text{card} \{ \eta_s, s \in D_n : h_l = \{m\}_l \} \tag{C.18}$$

où h est définie par (C.14)

où $\{n\}_l$ est donné par :

l	1	2	3	4	5	6	7
$\{m\}_l$	8	6	4 et 8	4 et 6	2 et 8	2, 4 et 6	4 et 0

Tableau C.3. valeurs $\{m\}_l$

Ces mêmes constantes sont utilisées dans l'algorithme EM (V.54).

BIBLIOGRAPHIE

- [AUD-97] L. Audral. *Analysis of Multi-Image Magnetic Resonance Acquisitions for Segmentation and Quantification of Cerebral Pathologies*, Rapport de Thèse, Université TELECOM Paris, France, 1997.
- [BEL-98] A. Belhadj-Aissa. *Contribution au Logiciel d'Analyse et de Traitement D'Images Satellitaires L.A.T.I.S. Analyse Spatiale-Spectrale d'Images Satellitaires Appliquée à la cartographie Thématique*, Thèse de Doctorat d'état, Institut d'électronique, Université U.S.T.H.B, Algérie, Avril 1998.
- [BES-89] J. Besag, "Towards Bayesian image analysis," *Journal of Applied Statistics*, vol. 16, pp. 395-407, 1989.
- [BLA-87] A. Blake and A. Zisserman, "Visual reconstitution," *M. I. T. Press Series in Artificial Intelligence*, 1987.
- [BOV-88] A. C. Bovik and D. C. Munson, "On detecting edges in speckle imagery," *IEEE Trans. Acoustics, Speech, and signal Processing*, vol. 36 pp. 1618-1627, October 1988
- [CHE-85] R. Chellapa and S. Chatterjee, "Classification of texture using Gaussian Markov random fields," *IEEE Trans. Acoustics, Speech, and signal Processing*, vol. 33 pp. 559-563, August 1985
- [COA-97] S. Coarsi, G. L. Gagnani, S. Medicina, M. Pastorino and G. Zunino "Microwave Imaging Based on a Markov random field model," *Trans. IEEE Trans Antennas and Propagation*, vol. 42 293-303, March 1997.
- [COQ-96] J.-M Cocquerez, S. Phillip. *Analyse d'Images*
- [CRO-83] G. R. Cross and A. K. Jain, "Markov random field texture models," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 5, pp. 25-39, January 1983.
- [DEG-98] S. R. DeGraaf, "SAR imaging via 2-D modern spectral estimation," *IEEE Trans. Image Processing*, vol. 7 pp. 729-761, May 1998.
- [DER-87] H. Derin and H. Elliot, "Modeling and segmentation of noisy and textured images using Gibbs random fields," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 9 pp. 39-55, January 1987.
- [DER-88] H. Derin, P. A. Kelly and K. D. Hartt, "Adaptive segmentation of speckled images using a hierarchical random field model," *IEEE Trans. Acoustics, Speech, and signal Processing*, vol. 36 pp. 1628-1641, October 1988
- [DUB-89] R. C. Dubes and A. K. Jain, "Random field models in images analysis," *Journal of*

Applied Statistics, vol. 16, pp. 131-164, 1989.

- [DUT-95] V. Dutt. *Statistical Analysis of Ultrasound Echo Envelope*, Ph.D. Thesis, Faculty of the Mayo Graduate School, USA, August 1995.
- [ELF-97] I. M. Elfadel and R. W. Picard, "Gibbs random fields, coocurrences and texture modeling," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 16 pp. 24-37, January 1997.
- [FAO-89] FAO/ESA joint study, "Principales of Radar Imagery", RSC Series 46, Food and Agriculture Organisation of United Nations, Rome, 1989.
- [FIG-97] M. Figueiredo and J. Letão, "Unsupervised image restoration using compound Gauss-Markov random fields and the MDL principle," *IEEE Trans. Image Processing*, vol. 4 pp. 1089-1102, August 1997.
- [FIG-94] M. Figueiredo and J. Letão, "Adaptive discontinuity in image restoration," in *Proc. IEEE. Int. Conf. Image Processing, ICIP'94*, Austin, TX, 1994, vol. II, pp. 665-66.
- [GEM-84] S. Geman and D. Geman, "Stochastic relaxation, Gibbs distribution, and the Bayesian restoration of images," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 6 pp. 721-741, November 1984.
- [GIR-99] M. J. Girard, C. Girard. *Traitement des Données de Télédétection*, Dunod, Paris, France, 1999.
- [HAN-88] R. R. Hansen and R. Chellapa, "Two-dimensional robust spectrum estimation," *IEEE Trans. Acoustics, Speech, and signal Processing*, vol. 36 pp. 1051-1066, July 1988
- [HAR-79] R. Haralick, "Statistical and structural approaches to textures," *Proceedings IEEE*, vol. 67, pp. 786-804, May 1979.
- [HAR-95] J. P. Hardange, P. Lacomme. *Radars aéroportés et spatiaux*, Masson, Paris, France, 1995.
- [HSI-89] J. Y. Hsiao and A. A. Sawchuk, "Supervised texture image segmentation using feature smoothing and probabilistic relaxation techniques," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 2 pp. 1279-1292, December 1989.
- [JAO-97] F. Jaquis. *Techniques de Radargrammétrie. Filtrage et Détection des Structures. Application à des Images ROS-ERS1*, Ph.D. Thesis, Université de Joseph-Fourier Grenoble, France, Octobre 1997.
- [JAY-84] K. Pratt. *Digital Coding of Waveforms. Principles and Applications to Speech and Vision*, Prentice-Hall, New Jersey, USA, 1984.

- [KAT-94] Z. Kato. *Modélisation Markoviennes Multirésolutions en Vision par Ordinateur. Applications à la Segmentation d'Images SPOT*, Ph.D. Thesis, Université de Nice Sophia Antipolis, France, Décembre 1994.
- [KRI-97] S. Krishnamachari and R. Chellapa, "Multiresolution Gauss- Markov random fields models for texture segmentation," *IEEE Trans. Image processing*, vol. 6 pp. 251-256, February 1997.
- [KUN-93] M. Kunt, G. Grandlund, M. Kocher. *Traitements Numériques des Image*, Presses Polytechniques et Universitaires Romandes, Losane, Suisse. 1993.
- [LI-96] Z. Li, "On discontinuity-adaptive smoothness priors in computer vision," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 17 pp. 576-586, June 1996.
- [MAS-94] N. D. A. Mascarenhas and A. C. Frery, "SAR image filtering with ICM algorithm," in *Proc. IEEE. Int. Conf. Geoscience and Remote Sensing Symposium, IGRASS'94*, Pasadena, CA, 1994, vol. IV, pp. 2185-2187.
- [MAT-97] P. Mathieu, L. Dirat, X. Dupuis and M. Barlaud, "Speckle reduction with edge-preserving," in *Proc. IEEE. Int. Conf. Acoustics Speech, and Signal Processing, ICASP'97*, New York, 1997, pp. 2785-2788.
- [MIG-97] M. Mignotte, C. Collet, P. Pérez and B. Bouthemy, "Unsupervised Markovian segmentation of sonar images," in *Proc. IEEE. Int. Conf. Acoustics Speech, and Signal Processing, ICASP'97*, New York, 1997, pp. 2781-2784.
- [MET-53] N. Metropolis, A. W. Rosenbluth, M. N. Rosenbluth, A. H. Teller E. Teller, "Equations of state calculations by fast computing machine," *Journal of chemistries and Physics*, vol. 21 pp. 1087-1091, 1953
- [MOR-96] G. Morris, L. Harkness. *Airoborne Pulsed Doppler Radar*, Artech House, Norwood, USA. 1996.
- [MUS-95] M. C. Musgrave and A. P. Quinn, "Texture Analysis of terrain images using Markov random field," in *Proc. IEE. Int. Conf. Image Processing and its applications*, Edirburgh, UK, 1995, N°410, pp. 781-785.
- [NGU-93] H. H. Nguyen and P. Cohen, "Gibbs random fields, fuzzy clustering and segmentation of textured images," *IEEE Trans. Graphical Models and Image processing*, vol. 55 pp. 1-19, January 1993.
- [PAN-97] Y. Pan-Yu. *Spectres de Processus de Markov*, Ph.D. Thesis, Institut d'Informatique et Mathématiques Appliquées de Grenoble, France, Juin 1997.
- [PAP-84] A. Papoulis. *Probability, Random Variables and Stochastic Process*, McGraw-Hill. New York, USA. 1984.

- [POS-87] J.-G Postaire. *De l'Image à la Décision*, Dunod, Paris, France. 1987.
- [PRA-91] K. Pratt. *Digital Image Processing*, Wiley-Interscience, New York, USA, 1991.
- [RIG-92] E. Rignot and R. Chellapa, "Segmentation of polarimetric synthetic aperture radar data," *IEEE Trans. Image Processing*, vol. 1 pp. 281-299, July 1992.
- [ROS-97] S. M. Ross. *Simulation*, Academic Press, New Jersey, USA, 1997.
- [SMA-98] M. Youcef Smara. *Contribution au Système d'Analyse et de Traitement D'Images Satellitaires L.A.T.I.S. Evaluation et Correspondance Terrain-Image Classifiée et Intégration d'Images Multisources Optiques et Radar SAR*, Thèse de Doctorat d'état, Institut d'électronique, Université U.S.T.H.B, Algérie, Avril 1998.
- [SOL-96] S. Solberg, T. Taxt and A.K. Jain, "A Markov random field model for classification of multisource satellite imagery," *IEEE Trans. Geoscience and Remote sensing*, vol. 34 pp. 100-113, January 1996.
- [SPA-87] A. Spataru. *Fondements de la Théorie de la Transmission de l'Information*, Presses Polytechniques Romandes, Lausanne, Suisse, 1987.
- [SZI-97] T. Szirányi and S. Zerubia, "Markov random field image segmentation using cellular neural network," *IEEE Trans. Circuits and Systems*
- [TOM-78] K. Tomiyasu, "Tutorial review of synthetic-aperture radar(SAR) with applications to imaging of the ocean surface," *Proceedings IEEE*, vol. 66, pp. 563-584, May 1978.
- [THO-84] L. Thourel. *Initiation aux techniques modernes des radars*, SUP'AERO. Toulouse, France. 1984.
- [WOO-74] J. W. Woods, "Two-dimensional discrete Markovian fields," *IEEE Trans. Information Theory*, vol. 18 pp. 232-240, March 1974.
- [WOO-76] J. W. Woods, "Two-dimensional Markov spectral estimation," *IEEE Trans. Information Theory*, vol. 22 pp. 552-588, March 1976.
- [WOO-78] J. W. Woods, "Markov random modeling," *IEEE Trans. Automatic control*, vol. 23 pp. 846-855, October 1978.
- [ZHA-94] J. Zhang and D. Modestino, "Maximum likelihood parameter estimation for unsupervised stochastic model-based image segmentation," *IEEE Trans. Image processing*, vol. 3, pp. 404-420, July 1994