

THÈSE

présentée à

L'Université de Bretagne Occidentale

U.F.R. Sciences et Techniques

en vue de l'obtention du titre de

DOCTEUR DE L'UNIVERSITÉ DE BRETAGNE OCCIDENTALE

mention: Electronique

par

Max MIGNOTTE

Titre de la Thèse :

Segmentation d'images sonar par approche markovienne hiérarchique non supervisée et classification d'ombres portées par modèles statistiques

soutenue le 3 juillet 1998 devant la commission d'examen composée de :

W. PIECZYNSKI	Professeur à l'INT d'Evry	Rapporteur
J. ZERUBIA	Directeur de recherche à l'INRIA sophia-Antipolis	Rapporteur
Examineur :		
P. BOUTHEMY	Directeur de recherche à l'INRIA/IRISA Rennes	Dr. de thèse
L.C. CALVEZ	Professeur à l'Université de Bretagne Occidentale (UBO)	
C. COLLET	Maître de conférences à l'Ecole navale-UBO	
P. PÉREZ	Chargé de recherche à l'INRIA/IRISA Rennes	
M. GRANGER	Ingénieur de Recherche DGA	Membre invité

Travail effectué au sein du laboratoire
Groupe de Traitement du Signal de l'Ecole navale

Remerciements

Cette thèse a été réalisée au sein du laboratoire GTS (Groupe de Traitement du Signal) de l'Ecole navale, en collaboration avec l'IRISA (Institut de Recherche en Informatique et Systèmes Aléatoires) et le GESMA (Groupe d'Etude Sous-Marines de l'Atlantique). Cette étude a été financée par la DRET (Direction des Recherches Etudes et Techniques de la DGA). J'aimerais remercier avant tout cet organisme à travers Monsieur Granger, ingénieur de Recherche DGA.

Je remercie Monsieur Leon-Claude Calvez, Professeur à l'Université de Bretagne Occidentale d'avoir bien voulu accepter de présider le jury de cette thèse.

Je remercie aussi Madame Josiane Zerubia, directrice de recherche à l'INRIA et Monsieur Wojciech Pieczynski, Professeur à l'INT d'Evry d'avoir accepté la lourde tâche de rapporter ce travail et d'y avoir prêté une attention soutenue. Qu'ils soient vivement remerciés pour le temps qu'ils y ont consacré, et pour les remarques constructives qu'ils ont apportées.

J'adresse tout mes sincères remerciements à Monsieur Patrick Bouthémy, directeur de recherche INRIA et directeur de ma thèse, pour la confiance et le soutien qu'il m'a accordés ainsi que les nombreux conseils qu'il m'a prodigués pendant toute la durée de mes travaux. Qu'il en soit ici chaleureusement remercié.

Je tiens également à remercier Christophe Collet, Maître de conférence à l'école navale et à l'Université de Bretagne Occidentale pour la confiance qu'il n'a cessée de m'accorder, pour l'intérêt qu'il a porté à mon travail, et aussi pour ses nombreuses critiques.

Je tiens à exprimer toute ma gratitude à Patrick Pérez, chargé de recherche à l'IRISA, pour ses nombreuses aides en analyse multigrille et en mathématique. J'ai ainsi pu apprécier sa compétence scientifique et son humilité. Qu'il trouve ici l'expression de ma plus grande sympathie.

Je remercie également Monsieur Bruno Ramstein, Professeur et Directeur de l'enseignement scientifique et de recherche à l'Ecole navale qui m'a accueilli au Laboratoire Groupe de Traitement du Signal.

Je remercie aussi Madame Ferrenback, documentaliste au centre de Documentation de l'Ecole navale pour sa disponibilité lors de mes nombreuses recherches bibliographiques.

Mes remerciements vont également à l'ensemble des membres du laboratoire, Gilles Keryer, Koffi Yao, Françoise Schmitt, Franck Daout, Philippe Rostaing, ainsi que tous ceux qui ont contribué à ce que l'ambiance de travail au sein de ce projet soit bonne et amicale : Jean-marc Meniel, Annaïg Le Guen, Patrick Rivault, Elise Capitan, les différentes générations d'appelés du contingent (Laurent Bonnaud, David Salaun, Yannick Mareau, Ronan Fablet, Pierre Boutou, Sylvain Yon, Anthony Mézière, ...) et enfin à mes collègues de bureau et thésards de l'Ecole navale ; Pascal Galerne, Sandrine Bonnifay, Valérie Sauce, Jean-Noël Provost et particulièrement Hélène Thomas pour sa bonne humeur et sa gentillesse.

Table des matières

Glossaire	2
Introduction générale	11
1 Introduction au traitement d'images SONAR	15
1.1 Introduction	15
1.2 Imagerie SONAR	16
1.2.1 Architecture d'un SONAR	16
1.2.2 Processus de formation des images	18
1.3 Détection d'objets	19
1.4 Bruit en imagerie SONAR	20
1.4.1 Réverbération de fond et bruit de speckle	20
1.4.2 Bruit associé aux ombres acoustiques	21
1.5 Conclusion	21
I Estimation des paramètres	23
1 Estimation des paramètres du modèle de bruit	27
1.1 Introduction	27
1.2 Étude bibliographique	27
1.3 Estimateur MV des données complètes	29
1.3.1 Loi gaussienne	29
1.3.2 Loi de Rayleigh	29
1.3.3 Loi de Weibull	30
1.3.4 Résultats des estimateurs MV	33
1.4 Estimateur des données incomplètes	37
1.5 Algorithmes locaux	37
1.5.1 Algorithme EM	37
1.5.2 Algorithme SEM	41
1.6 Algorithme global	43
1.6.1 Algorithme ECI	45

1.7	Algorithmes des K moyennes	46
1.8	Méthode de segmentation courante	48
1.9	Relations entre les différentes méthodes d'estimation	49
1.10	Résultats expérimentaux	50
1.10.1	Algorithme des K -moyennes	50
1.10.2	Algorithmes locaux: EM et SEM	51
1.10.3	Algorithme global: ECI	55
1.11	Conclusion	58
2	Estimation des paramètres du modèle a priori	59
2.1	Étude bibliographique	59
2.2	Estimateur des données complètes du modèle a priori	60
2.2.1	Estimateur de Derin <i>et al.</i>	61
2.2.2	Résultats expérimentaux	61
2.3	Estimateur sur données incomplètes du modèle a priori	64
2.4	Estimation conjointe des paramètres	64
2.5	Conclusion	69
II	Segmentation	73
Introduction		75
1	Segmentation monoéchelle	77
1.1	Estimation du champ d'étiquettes	77
1.1.1	Estimateur du MAP	77
1.1.2	Estimateur du MPM	78
1.2	Optimisation	79
1.2.1	Recuit Simulé (RS)	79
1.2.2	Iterated Conditional Modes (ICM)	80
1.2.3	Technique de Monté Carlo (MC) permettant d'approcher le MPM	81
1.3	Résultats expérimentaux	81
1.4	Conclusion	83
2	Méthodes Hiérarchiques	87
2.1	Introduction	87
2.2	Étude bibliographique	87
2.3	Familles de modèles markoviens	88
2.3.1	Modèle markovien multirésolution (RMR)	88
2.3.2	Approches multimodèles	89
2.4	Modèles dont la fonction d'énergie est associée à une grille 2D	90
2.4.1	Approches par groupe de renormalisation	90

2.4.2	Modèle markovien multiéchelle (RME)	91
2.5	Modèles markoviens hiérarchiques	94
2.5.1	Modèle markovien multiéchelle de Bouman	94
2.5.2	Modèle hiérarchique de Kato <i>et al.</i>	99
2.6	Conclusion	100
2.7	Résultats des algorithmes hiérarchiques	100
2.7.1	Modèles hiérarchiques associés au MAP	101
2.7.2	Modèle hiérarchique associé au SMAP	101
2.7.3	Complexité calculatoire des algorithmes	102
2.8	Conclusion	108
3	Modèle de segmentation proposé	109
3.1	Introduction	109
3.2	Modèle Multigrille Causal en Échelle (MCE)	109
3.3	Estimation des paramètres du modèle SCM	112
3.3.1	Estimateur proposé	112
3.3.2	Tests sur des images synthétiques	113
3.4	Résultats expérimentaux de segmentation	114
3.5	Conclusion	123
4	Segmentation en trois classes	125
4.1	Introduction	125
4.2	Formulation du problème	125
4.3	Modèle de segmentation en trois classes	127
4.3.1	Introduction	127
4.3.2	Stratégie de segmentation en trois classes	128
4.4	Résultats expérimentaux	132
4.5	Conclusion	132
5	Segmentation d'images SONAR de grande taille	137
5.1	Segmentation d'images SONAR de grande taille	137
5.2	Conclusion	139
	Conclusion	141
III	Classification des ombres portées	143
	Introduction	145
1	Classification par modèle statistique	147
1.1	Introduction	147
1.2	Représentation de la forme prototype	147

1.3	Déformations associées	149
1.4	Détection de la classe d'objets considérée	150
1.4.1	Terme d'énergie ϵ_c liée aux contours des ombres	150
1.4.2	Terme d'énergie ϵ_r liée aux régions d'ombre	152
1.4.3	Détection et classification d'une classe d'objets	152
1.5	Conclusion	153
2	Techniques d'optimisation	155
2.1	Introduction	155
2.2	Descente de gradient	155
2.3	Recuit simulé	157
2.3.1	Résultats expérimentaux	159
2.4	Algorithmes génétiques	164
2.4.1	Principe	164
2.4.2	Comparaison avec les autres techniques d'optimisation	166
2.4.3	Méthodes hybrides	167
2.4.4	Niche écologique	168
2.4.5	Réajustement de la fonction d'adaptation	168
2.4.6	Descente en température	169
2.4.7	Résultats expérimentaux	169
2.5	Conclusion	182
	Conclusion	183
IV	Classification des fonds marins	185
1	Segmentation et classification des fonds marins	187
1.1	Introduction	187
1.2	Étape d'extraction de caractéristiques	188
1.3	Classification floue	190
1.4	Modèle de segmentation	193
1.5	Résultats expérimentaux	195
1.6	Conclusion	195
	Conclusion générale et perspectives	201
	Publications effectuées	205
	Bibliographie	207
	Annexe	213

A	Étude des estimateurs MV	215
A.1	Loi de Rayleigh : étude de l'estimateur MV $\hat{\alpha}_{MV}^2$	215
A.2	Loi de Weibull : étude de l'estimateur MV $\hat{\alpha}_{MV}^C$	216
B	Test du χ^2 et distance de Kolmogorov	219
C	Pyramides de données utilisées dans l'algorithme RMR	221
D	USIS	223
E	SMACOSS	225

Notations

Partie 1: Abréviations

SEM	Stochastic Expectation Maximisation.
EM	Expectation Maximization.
ECI	Estimation Conditionnelle Itérative.
ECIG	ECI Globale (méthode d'estimation conjointe des paramètres proposée).
MC	Monté Carlo.
SC	Segmentation Courante.
RSA	Recuit Simulé Adaptatif.
ICMA	ICM adaptatif.
MV	Maximum de vraisemblance.
MAP	Maximum A Posteriori.
MPM	Modes of Posterior Marginals.
MF	Mean Field.
POS	Partial Optimal Solution.
BICR	Borne inférieure de Cramer-Rao.
EMG	EM Gibbsien.
LSQR	Least Squares (méthode d'estimation des paramètres de la distribution de Gibbs proposée par Derin <i>et al.</i>).

Notations générales

$\mathbb{N}$	Ensemble des entiers naturels.
$\mathbb{R}$	Ensemble des nombres réels.
$\mathcal{N}(y; \mu, \sigma^2)$	Loi normale de paramètres μ (moyenne) et de variance σ^2 .
$\mathcal{R}(y; min, \alpha^2)$	Loi de Rayleigh décalée de paramètres min (minimum) et α^2 .
$\mathcal{W}(y; min, \alpha, C)$	Loi de Weibull décalée de paramètres min , α et C .
$\mathcal{L}$	Fonction de vraisemblance.
$I(.)$	Information de Fisher.
$card(E)$	Cardinal de l'ensemble fini ou dénombrable E .
$E[X]$	Espérance mathématique de la v.a X .
$E[. .]$	Espérance conditionnelle.
$var[X]$	Variance de la v.a. X .
$\triangleq$	Définition.
$[p]$	L'indice désigne ici l'itération.
V^t	Transposée du vecteur.
∇	Opérateur gradient.
$S_{\Phi}(y)$	Segmentation de y utilisant la valeur courante Φ du paramètre.
$\underline{A}$	Matrice A .
$\underline{A}^t$	transposée de la matrice A .

Partie 1: Chapitre 1

$N = S $	Nombre de sites.
K	Nombre de classes.
$Y \dots (y)$	Champ d'observation. (réalisation du champ d'observation).
$X \dots (x)$	Champ des étiquettes. (réalisation du champ d'étiquettes).
$(X, Y) = Z$	Champ couplé d'étiquettes et d'observations. Données complètes.
Ω	Espace d'état des étiquettes.
$x_s = e_i$	Élément de Ω , étiquette associée au site s de S .
$\Phi = (\Phi_x, \Phi_y)$	Paramètres du mélange de distribution et de la distribution de Gibbs.
Φ_x	Paramètres de la distribution de Gibbs.
Φ_y	Paramètres du mélange de distribution (ou du modèle de bruit).
$P_{X,Y}(x, y)$	Probabilité ou densité de probabilité associée à la réalisation (x, y) du champ (X, Y) (distribution jointe).
$P_{X/Y}(x/y)$	Probabilité ou densité de probabilité associée à la réalisation x du champ d'étiquettes conditionnellement à $Y = y$ (distribution <i>a posteriori</i>).
$P_{Y/X}(y/x)$	Probabilité ou densité de probabilité associée à la réalisation y du champ d'observation conditionnellement à $X = x$ (vraisemblance des observations).
$P_X(x)$	Probabilité ou densité de probabilité associée à la réalisation x du champ d'étiquettes (marginale, ou distribution <i>a priori</i>).
$P_Y(y)$	Probabilité ou densité de probabilité associée à la réalisation y du champ d'observation.
$\mathbf{x}_i$	Vecteur à K dimensions dont les composantes sont toutes initialisées à zéro excepté pour la $k^{\text{ième}}$ composante associée à l'étiquette de y_i .
$\mathbf{x}_{ik}$	$k^{\text{ième}}$ composante du vecteur $\mathbf{x}_i$.
$U(y_i/\Phi_y)$	$=(\log P_{Y_i/X_i, \Phi_y}(y_i/e_1, \Phi_y), \dots, \log P_{Y_i/X_i, \Phi_y}(y_i/e_K, \Phi_y))$. Vecteur à K dimensions calculé sur la base du paramètre Φ_y et regroupant la vraisemblance de l'observation Y_i .
$V(\Phi_x)$	$=(\log P_{X_i/\Phi_x}(e_1/\Phi_x), \dots, \log P_{X_i/\Phi_x}(e_K/\Phi_x))$ Vecteur à K dimensions calculé sur la base du paramètre Φ_x et regroupant les différentes proportions du mélange.
$\mathbf{x}$	Vecteur à trois dimensions ou "échantillon" caractérisant une image.
M	Nombre d'échantillons de l'image.
C_i	Groupeement i .
c_i	Centre du groupeement C_i .

Partie 1: Chapitre 2

$\Phi_x = (\beta_1, \beta_2, \beta_3, \beta_4)$	Paramètres de la distribution de Gibbs.
β_1	Cliques horizontales.
β_2	Cliques verticales.
β_3	Cliques diagonales droites.
β_4	Cliques diagonales gauches.
ν_s	Voisinage associé au site s .
X_{ν_s}	Ensemble des v.a. du voisinage de s .
η_i	Configuration particulière du voisinage.
$P_{X_s/X_{\nu_s}}(x_s/x_{\eta_s})$	Probabilité de X_s conditionnée à la configuration de ses voisins.
$P_{X_s/X_{\nu_s}}(x_s/\eta_i)$	Probabilité d'apparition de l'étiquette X_s avec la configuration particulière du voisinage η_i
$P_{X_{\nu_s}}(\eta_i)$	Probabilité d'apparition du voisinage η_i seulement.

Partie 2: Abréviations

RS	Recuit simulé.
RD	Relaxation Déterministe.
RMR	Relaxation Multirésolution.
RME	Relaxation Multiéchelle.
MG	Relaxation Multigrille.
MSRF	MultiScale Random Field (Modèle de <i>Bouman</i>).
SMAP	Sequential MAP (MAP “séquentiel” de Bouman).
LSQR _{2D}	Least Square 2D (méthode d’estimation du modèle <i>a priori</i> proposée par Derin et Elliot pour un modèle Markovien spatial).
LSQR _{3D}	Least Square 3D (système Markovien spatial et causal en échelle).
SCM ou MCE	Modèle Multigrille et Causal en Échelle (Scale Causal Multigrid).
RAG	Region Adjency Graph (Graphe d’adjacence).
MTA	Multi-Temperature Annealing (Recuit multi-température).
RSB	Rapport Signal sur Bruit.

Notations générales

$C(X, x)$	Fonction de coût ou fonction perte.
δ	Distribution de Dirac.
$odd(i)$	Renvoie 1 si i est impair, -1 si i est pair.
$[i]$	Partie entière de i .
$\not\approx$	Assez différent de.

Partie 2: Chapitre 1-2

Ω	Espace d'état des étiquettes.
Y^i	Champ d'observation au niveau de résolution i .
E	Ensemble des configurations sur S .
$x \in E$	Configuration quelconque sur S .
$U(x, y) = U(x) + V(x, y)$..	Energie associée au champ de Gibbs (X, Y) .
$U(x) = \sum_{c \in \mathcal{C}} U_c(x)$	Energie contextuelle.
$V(x, y) = \sum_{s \in S} V_s(x_s, y_s)$..	Energie d'attache aux données.
$B^i = \{B_k^i\}_{k=1, \dots, N_i}$	Partition de S au niveau i .
B_k^i	k -ième cellule du niveau i .
N_i	Nombre de cellules au niveau i .
E^i	Sous-ensemble de configurations au niveau i .
X^i	Champ d'étiquettes réduit d'ensemble de configurations E^i .
q_d^i	Surface de contact de la clique diagonale au niveau de résolution i .
q_{hv}^i	Surface de contact d'une clique horizontale ou verticale au niveau de résolution i .
x_k^i	Valeur prise par la configuration x de E^i sur tous les sites de la cellule B_k^i .
$V_k^i(x_k^i, y)$	Somme des attaches aux données pour tous les sites de la cellule B_k^i .
$\mathcal{C}_k^i$	Ensemble des cliques incluses dans le bloc B_k^i .
$\mathcal{C}_{k_1, k_2}^i$	Ensemble des cliques dont les intersections avec $B_{k_1}^i$ et $B_{k_2}^i$ sont non-vides.
$\mathcal{G}$	Structure de voisinage sur S .
$\mathcal{G}^i$	Structure de voisinage sur S^i .
$\mathcal{G}_B^i$	Structure de voisinage sur B^i .
$U^i(x^i, y)$	Fonction d'énergie associée au champ (X^i, Y) .
$\beta_1^i, \beta_2^i, \beta_3^i, \beta_4^i$	Potentiels associés aux cliques horizontales, verticales, diagonales droites et gauches au niveau de résolution i .
$d(s)$	Unique père de s ou (ascendant de s).
$d^{-1}(t)$	Ensemble des fils de t (descendant de t).
$P_{X_s^i/X_{\nu_s}^{i+1}}(e_m/e_k)$	Probabilité de transition inter-échelle pour le quadarbre.
$P_{X_s^i/X_{\nu_s}^{i+1}}(e_m/e_k, e_i, e_l)$	Probabilité de transition inter-échelle pour le graphe pyramidal.
$\Theta_{i,0}$	Probabilité que l'étiquette reste la même des échelles $n+1$ à n pour le quadarbre.
$\Theta_{i,1}$	Probabilité que l'étiquette reste la même des échelles $i+1$ à i pour le graphe pyramidal.
z	Racine du quadarbre.
$l_s^i(k) \triangleq \ln P_{Y_s/X_s^i}(y_s/k)$	Fonction de vraisemblance au niveau n et pour le site s de la pyramide.

Partie 3: Abréviations

AG Algorithme Génétique.

Notations générales

$\text{sgn}(x)$ Fonction signe de x .

Partie 3: Chapitre 1

n	Nombre de points caractéristiques de la forme.
m	Nombre de degrés de liberté du modèle ou nombre de paramètres ou nombre de transformations linéaires considérées.
Θ	Vecteur aléatoire de dimension m associé aux différents paramètres des transformations linéaires considérées.
θ	Réalisation du vecteur de aléatoire Θ .
θ_j	$j^{\text{ième}}$ paramètre de θ .
$\gamma_0 = (x_1, y_1, \dots, x_n, y_n)^t$..	Forme prototype définie dans $\mathbb{R}^2$ et représentée par la suite des coordonnées des n points caractéristiques de la forme (vecteur de dimension $2n$).
$\mathbf{x}_i = (x_i, y_i)^t$	Coordonnées d'un point dans le plan.
γ_θ	Modèle déformable après transformation (vecteur de dimension $2n$).
s	Facteur d'échelle.
A_α	Matrice carrée ($2n \times 2n$) associée à la rotation d'angle α du modèle γ_0 .
A_h	Matrice carrée ($2n \times 2n$) associée à l'élongation de facteur h du modèle γ_0 .
A_k	Matrice carrée ($2n \times 2n$) associée au biais de paramètre k du modèle γ_0 .
t	Vecteur de translation globale de dimension $2n$.
$P_{\Gamma_\Theta}(\gamma_\theta) = P_\Theta(\theta)$	Distribution associée au processus γ_θ (modèle <i>a priori</i>).
$P_{X/\Theta}(x/\theta)$	Vraisemblance des observations.
$P_{\Theta/X}(\theta/x)$	Probabilité <i>a posteriori</i> .
x'	Image binaire des contours.
ϕ_{s_0}	Potentiel élémentaire créé par un pixel de contour d'ombre.
$\Phi_{x'}$	Champ de potentiel associé à l'énergie d'interaction liée aux contours d'ombre.
$\epsilon(\theta, x)$	Énergie d'interaction entre le modèle déformable γ_θ et les données observées x .
$\epsilon_c(\theta, x)$	Énergie d'interaction liée aux contours.
$\epsilon_r(\theta, x)$	Énergie d'interaction liée aux régions.

Partie 3: Chapitre 2

$\Delta\theta$	Pas d'intégration de chaque paramètre θ .
k	Compteur d'itérations ou de générations.
N	Nombre d'individus de la procédure d'exploration génétique.
L	Nombre de gènes par paramètre.
c_i	$i^{\text{ème}}$ gène du chromosome.
c_{ij}	$j^{\text{ème}}$ paramètre du $i^{\text{ème}}$ gène du chromosome.
$\underline{\theta_i^k}$	Chaînes (ou chromosomes) à l'itération k .
$\mathcal{F}$	Fonction d'évaluation ou d'adaptation.
$p(\underline{\theta_i^k})$	Probabilité de sélection du chromosome $\underline{\theta_i^k}$ pour la génération $k + 1$.
P_{cross}	Taux de croisement.
P_{mut}	Taux de mutation.
$d(\underline{\theta_i}, \underline{\theta_j})$	Fonction de partage entre le chromosome $\underline{\theta_i}$ et le chromosome $\underline{\theta_j}$.
π_j	Précision de codage pour le paramètre θ_j .
T_0	Température initiale.
T_f	Température finale.
a	Taux de décroissance en température.

Partie 4: Chapitre 1

Γ	Contour (d'une forme).
C	Compacité (d'une forme).
ξ	Elongation (d'un contour Γ).
α	Orientation (d'un contour Γ).
$\mathcal{C}$	Matrice de corrélation (d'un contour Γ).
M	Nombre de contours ou de formes existant dans une imagerie.
C_{moy}	Compacité moyenne des différentes formes existant dans une imagerie.
σ_{α}^2	Variance des orientations associées aux différents contours existant dans une imagerie.
ξ_{max}	Elongation maximale (d'un contour Γ) rencontrée dans une imagerie.
N_{max}	Taille maximale (d'un contour Γ) rencontrée dans une imagerie.
$\mu_{w_i}(x_k)$	Degré d'appartenance de l'imagerie k à la classe w_i .
$\mu_{w_i}(F_{kj})$	Fonction d'appartenance associée à l'attribut caractéristique F_{kj} .
S	Grille rectangulaire de N images s .
$X = \{X_s, s \in S\}$	Vecteur de variables aléatoires (champ des observations).
$W = \{W_s, s \in S\}$	Vecteur de variables aléatoires (champ des étiquettes).
x_s	Réalisation de la v.a X_s ou vecteur d'attributs caractéristiques calculés sur l'imagerie s .
w_s	Variable cachée affectée à l'imagerie s prenant ses valeurs dans l'ensemble $\{w_0, w_1, w_2, w_3, w_4\}$.
w_0	Étiquette "sable".
w_1	Étiquette "rides".
w_2	Étiquette "dunes".
w_3	Étiquette "cailloux".
w_4	Étiquette "rochers".

Introduction générale

Le SONAR haute résolution constitue un moyen efficace pour observer la très grande variété d'objets reposant sur les fonds marins. Ces dernières années, de nombreuses améliorations ont rendu ces SONAR de plus en plus performants (utilisation à des profondeurs plus importantes, zones explorées plus vastes, plus grande finesse d'analyse, visualisation des résultats sous forme d'images . . .). En contre partie, la quantité d'informations présentées aux opérateurs a sensiblement augmenté et rend aujourd'hui nécessaire d'automatiser la détection et la classification de ces objets. Le but recherché dans le domaine de la classification en imagerie SONAR est, dans un premier temps, d'être à même de pouvoir différencier les objets naturels des objets manufacturés (épave de bateau, pipe-line, . . .). Une autre application de la classification automatique de ces objets est la lutte contre les mines. En effet, chaque objet reposant sur le fond peut être une menace éventuelle pour les navires de guerre et les navires marchands. Il faut donc être en mesure de lever le doute quant à la nature de ces objets, pour éviter la mise en œuvre systématique de moyens lourds de destruction.

La classification de ces objets en tant que "*objets naturels*" (rochers, cailloux, . . .) ou "*objets manufacturés*" (épaves de bateaux, pipe-line, mines . . .) est alors réalisée grâce à une analyse de la forme de l'ombre qu'ils produisent sur les images SONAR. À cette fin, l'automatisation de la phase de classification requiert une première étape qui a pour but de réduire ou simplifier l'information issue de l'image SONAR afin de la rendre plus facilement exploitable. Cette analyse de bas niveau s'appelle la *segmentation*, et consiste à produire une partition de l'image initiale en régions possédant certaines caractéristiques d'homogénéité et correspondant aux différentes composantes de la scène. En chacun des pixels, cette phase de détection décidera de l'appartenance ou non du pixel traité à une classe. Pour une image SONAR, ces zones d'intérêt sont au nombre de trois :

- Une zone constituée par l'*écho* des différents objets reposant sur le fond marin et pour laquelle la réverbération a une intensité maximale. Pour une image issue d'un SONAR classificateur, nous verrons que cet *écho* est faible, peu discriminant, et souvent inexistant.
- Une zone très caractéristique de la nature des objets et que l'on qualifie d'*ombre*. Cette zone résulte de l'absence de réverbération du signal SONAR (et correspond en fait à la zone qui est masquée acoustiquement par les différents objets reposant sur les fonds marins).
- Une zone appelée *réverbération de fond* qui correspond à la réverbération du signal SONAR sur le fond marin.

Toutefois, les résultats obtenus par les traitements "classiques" de segmentation (seuillages de l'image, suivis d'opérations simples de morphologie mathématique) ne sont généralement pas satisfaisants en raison de la présence d'un fort bruit de speckle inhérent aux images SONAR. Les formes d'ombres obtenues après cette segmentation sont parfois éloignées de leurs formes effectives. Ce résultat est lié aux principes de ce type d'approche. En effet, le traitement de chaque pixel y est réalisé de façon indépendante¹. De plus les processus physiques de formation de l'image SONAR ne sont pas pris en compte. Cette phase de segmentation est pourtant essentielle et conditionne ensuite la qualité des résultats de l'étape de classification dont le but est d'affecter à chacun des objets dont l'ombre portée a été détectée l'une des deux classes suivantes "*objet naturel*" ou "*objet manufacturé*".

1. excepté l'approche proposée en [93] par J. Sivakumar et J. Goutsias.

Pour l'étape de classification, une solution simple, proposée jusqu'à présent en imagerie SONAR, consiste à extraire des attributs pertinents permettant de caractériser la forme de l'ombre (attributs statistiques, géométriques, spectraux ...), et à exploiter ces informations comme entrées d'un classifieur quelconque de manière à identifier les différentes classes recherchées. Cette solution est classique en reconnaissance des formes, simple à implanter et quelquefois bien adaptée à certains types de problèmes. Néanmoins cette technique de classification reste largement dépendante de l'étape d'extraction des caractéristiques pour laquelle il n'existe pas de règles générales pour déterminer le nombre optimal d'attributs ainsi que le caractère discriminant de ceux-ci. De plus, cette approche nécessite une grande base de données pour l'apprentissage du classifieur. Remarquons aussi que l'ombre portée que l'on cherche à classer peut être modifiée par l'ombre portée de cailloux, l'ombre portée d'une dune ou l'ombre portée créée par des rides de sable. Dans ce cas, les attributs statistiques de cette ombre portée s'en trouvent altérés et des erreurs de classification peuvent en découler.

Dans notre application, certaines propriétés, locales ou globales, liées aux informations que l'on cherche à obtenir (carte de segmentation dans une première étape, puis la classe associée à chaque ombre portée), peuvent être prises en compte et intégrées dans un modèle statistique incluant aussi les processus physiques de formation de l'image SONAR. En particulier, les bruits multiples intervenant dans les différentes étapes du processus de formation de l'image doivent être appréhendés. A cette fin, la théorie bayésienne de la décision (ou de l'estimation) fournit un cadre méthodologique unifié et bien maîtrisé permettant d'intégrer et de faire coopérer, au sein d'un même modèle statistique des connaissances *a priori* sur ces primitives (ou étiquettes) et cette description physique du lien unissant les observations aux primitives.

- Dans le cas d'une segmentation, ces connaissances *a priori* sur les propriétés des primitives recherchées sont locales. Elles permettent d'exprimer simplement le fait que les pixels voisins doivent avoir un niveau de gris similaire et être situés dans la même région. Une telle régularité est bien modélisée par les champs de Markov. Placée dans le contexte de l'estimation bayésienne, la recherche de l'image segmentée se réduit à un *problème d'optimisation globale*. Ce problème reste néanmoins difficile dans la mesure où les fonctions d'énergie à minimiser sont complexes, généralement non linéaires, et dépendent d'un nombre considérable de variables. De ce fait, on ne peut que tenter d'approcher une solution du problème, en mettant en œuvre des algorithmes de relaxation appropriés : soit des algorithmes stochastiques (ou algorithmes de *recuit simulé*) qui convergent théoriquement vers un minimum global de la fonction d'énergie, indépendamment de l'initialisation, mais qui sont extrêmement lents ; soit des algorithmes déterministes qui convergent beaucoup plus rapidement, mais vers des minima locaux dépendant de l'initialisation.

Pour repousser ces contraintes, une nouvelle approche a été développée : la représentation et l'analyse hiérarchiques des images. Ce type d'analyse qui peut porter sur les observations (analyse multirésolution des données), ou sur l'algorithme d'optimisation (analyse multigrille), présente de nombreux avantages. Il permet de diminuer la complexité calculatoire mais aussi de diminuer la complexité des problèmes d'optimisation posés (moindre sensibilité aux minima locaux), et est utile pour rendre compte de l'information à des niveaux de descriptions différents (pixels, régions ...). Ce type de représentation permet également de propager plus rapidement des interactions entre primitives locales et de conduire à des solutions de meilleure qualité. Cette démarche séduisante a été utilisée avec succès dans le cas de la segmentation d'images satellitaires, la segmentation au sens du mouvement ou pour d'autres applications ... Dans ces conditions, il semble naturel de chercher à l'étendre au cas spécifique de la segmentation des images SONAR. Afin de rendre cette procédure automatique ou *non supervisée*, il est nécessaire de plus d'estimer un certain nombre de paramètres du modèle le caractérisant.

La recherche d'un modèle markovien hiérarchique, spécifiquement adapté au problème de la segmentation des images SONAR et associé à une stratégie d'optimisation efficace et rapide d'une part, et à l'estimation des paramètres de ce modèle d'autre part, constitue le premier volet de notre travail de recherche.

- En ce qui concerne le problème de classification, les connaissances *a priori* sur les propriétés des primitives recherchées sont globales. Elles permettent de traduire le fait que, contrairement à un objet naturel, un objet manufacturé est *a priori* constitué d'un assemblage d'éléments de forme géométrique simple. Ces objets se traduisent sur l'image SONAR par la présence d'ombres dont les contours présentent des segments de droite. Dans le cas d'un objet de forme géométrique simple (mine cylindrique par exemple), l'ombre portée est un parallélogramme théoriquement parfait. Dans le cas d'un objet sphérique (mine sphérique

par exemple), l'ombre portée reste très caractéristique et se traduit par une sorte d'ellipse. Contrairement aux objets manufacturés, l'ombre créée par des rochers ou des cailloux est chahutée et de forme aléatoire. Cette connaissance *a priori* globale peut être décrite efficacement par un modèle statistique représentatif de l'ombre portée de la classe d'objet que l'on cherche à détecter. Cette structure élémentaire doit être associée à un ensemble de déformations (transformations linéaires) représentant l'ensemble des configurations jugées admissibles pour notre forme prototype. Placé dans le contexte de l'estimation bayésienne, le problème de la détection d'une classe d'objet est équivalent à un problème d'estimation des paramètres de déformation du modèle. Cette estimation conduit à la minimisation d'une fonction d'énergie globale complexe et non linéaire. Contrairement à la fonction d'énergie liée à la segmentation, celle-ci dépend d'un nombre assez restreint de variables qui correspondent en fait au nombre de paramètres de déformation du modèle. Mais, cette fois-ci, chaque variable prend ces valeurs dans un intervalle continu et non plus discret. Les diverses approches qui ont pu être proposées à ce jour pour minimiser ce type de fonction d'énergie sont peu satisfaisantes, soit parce qu'elles sont lentes (c'est le cas des algorithmes de *recuit simulé*), soit parce qu'elles sont trop dépendantes de l'initialisation du modèle (algorithme de type *descente du gradient*). La minimisation d'une telle fonction d'énergie est un problème récent, difficile et qui reste à ce jour largement ouvert. C'est aussi à la résolution de ce type de problème que nous nous sommes attachés.

Plus précisément, la définition d'un modèle statistique de détection et de classification d'objet reposant sur une formulation bayésienne de ce problème, et la recherche d'un algorithme de relaxation optimale et rapide permettant de minimiser la fonction d'énergie associée à ce type de modélisation constitue la deuxième partie de notre travail de recherche.

Plan général de la thèse

Le **premier chapitre** de ce document est consacré à l'imagerie acoustique des fonds marins à l'aide de SONAR hautes fréquences. Le processus d'acquisition d'une image SONAR et le bruit de speckle lié à la réverbération du fond marin y sont également décrits.

La **première partie** de ce document, intitulée "Estimation des paramètres", est consacrée à l'estimation des paramètres du modèle markovien défini pour une segmentation *non supervisée* des images SONAR en deux classes (*ombre/réverbération*). En effet, une segmentation basée sur une stratégie bayésienne requiert la connaissance de certains paramètres de la loi $P_{X,Y}(x,y)$. X représente ici le champ des étiquettes et Y le champ des observations. Pour être plus précis, ces paramètres sont d'une part ceux associés à la loi $P_{Y/X}(y/x)$ qui caractérisent le modèle de bruit. Une bonne segmentation par une approche markovienne nécessite une connaissance appropriée de la nature du bruit présent dans l'image. Ce problème revient à identifier un mélange de lois statistiques et à estimer les paramètres associés à ces lois d'après la distribution des intensités observées. Ces paramètres incluent d'autre part ceux associés à la loi $P_X(x)$ qui caractérise et modélise les propriétés *a priori* du champ d'étiquettes que l'on définit comme étant une distribution de Gibbs. C'est l'estimation de ces paramètres qui va permettre d'introduire des contraintes génériques qui, dans le procédé de segmentation, traduisent les propriétés locales et globales du champ d'étiquettes (propriétés géométriques, homogénéité, variabilités spatiales, ...).

Pour l'estimation des paramètres du modèle de bruit, nous présenterons dans cette partie deux types de modélisation. Une reposant sur un mélange de lois différentes (i.e., une loi gaussienne pour modéliser la répartition des niveaux de gris situés dans une zone d'ombre et une loi de Rayleigh pour ceux situés dans la zone de réverbération) et une autre plus générale reposant sur un mélange de lois de Weibull. Dans un premier temps, nous comparerons les résultats obtenus par les algorithmes d'estimation classiques : SEM (*Stochastic Estimation Maximization*), EM (*Expectation Maximization*), ECI (*Estimation Conditionnelle Itérative*). Une solution originale au problème de l'initialisation de ces algorithmes d'estimation itératifs sera notamment présentée. Nous décrirons ensuite une approche permettant d'estimer conjointement ces deux types de paramètres, directement à partir de l'image, au sens du Maximum de Vraisemblance pour le modèle du bruit, et au sens des moindres carrés pour le modèle *a priori*.

La **seconde partie** de ce document, intitulée "Segmentation", concerne les principaux estimateurs utili-

sés pour une segmentation bayésienne ainsi que les algorithmes classiques monoéchelle liés à l’optimisation des champs markoviens. Nous présenterons les résultats expérimentaux d’une segmentation en deux classes (*ombre/réverbération*) obtenus par ces algorithmes sur des images SONAR. Le deuxième chapitre de cette partie sera consacré aux approches récentes permettant de résoudre efficacement et rapidement le problème d’optimisation précédemment évoqué. Il correspond à une approche déterministe et à des modèles qui associent une représentation statistique de l’image et une hiérarchisation de l’information. Ces méthodes sont appelées *multigrille*, *multirésolution*, *multiéchelle* ou plus généralement *hiérarchiques*. Dans le troisième chapitre de cette partie, nous introduirons un modèle de segmentation *non supervisé* spécifiquement adapté à la segmentation binaire des images SONAR. Son principe repose sur des interactions à la fois spatial et causal en échelle et une stratégie de minimisation multigrille. Des comparaisons expérimentales avec d’autres méthodes hiérarchiques sur des images SONAR réelles et synthétiques seront détaillées. Dans le quatrième chapitre, nous nous intéresserons à la segmentation en trois classes des images SONAR (*ombre/réverbération de fond/écho*). Même si l’*écho* ne doit pas constituer le critère déterminant qui permette de détecter et *a fortiori* de classer l’objet reposant sur le fond marin, il peut se révéler être une information complémentaire utile dans la phase d’interprétation. Nous avons proposé une démarche originale qui utilise la précédente segmentation en deux classes, et qui tient compte du nombre très peu élevé de pixels associés à la classe *écho* et des informations *a priori* sur les propriétés physiques de cette classe.

La **troisième partie** de ce document, intitulée “Classification des ombres portées”, est consacrée à la classification des ombres portées en imagerie SONAR. L’approche originale que nous proposons repose sur la définition d’un modèle statistique représentatif de l’ombre portée de la classe d’objets que l’on cherche à détecter. La détection repose ici sur la théorie bayésienne de la décision et utilise des caractéristiques extraites de l’image SONAR segmentée en deux classes (*ombre/réverbération*), ainsi que des techniques d’optimisation afin d’estimer les déformations de ce modèle au sens d’un critère statistique. Différentes techniques d’optimisation, stochastiques et déterministes, adaptées à notre problème d’estimation, seront largement décrites et testées dans le deuxième chapitre de cette troisième partie. L’approche que nous proposons exploite une procédure d’exploration génétique associée à une technique d’exploration locale (descente du gradient) et à un facteur de décroissance en température. Elle est à la fois rapide et efficace.

La **quatrième partie** de ce document concerne la “classification des fonds marins”. Dans le cadre d’une chaîne de classification automatique des objets reposant sur le fond marin, cette information peut se révéler utile dans la phase d’identification des ombres portées. L’approche que nous adoptons s’appuie sur une analyse des formes d’ombres que produit chaque type de fond. Un modèle markovien permet de spécifier, d’une part les propriétés d’homogénéité de la carte de segmentation/classification, et d’autre part d’exprimer la vraisemblance des observations par un module de décision flou.

Ces quatre parties sont illustrées par de nombreux résultats expérimentaux sur des images SONAR réelles ou synthétiques, attestant de la validité des techniques proposées. Enfin, dans la conclusion générale, nous tirons un bilan de ces travaux et proposons quelques perspectives de recherche associées à cette étude.

Chapitre 1

Introduction au traitement d'images SONAR

1.1 Introduction

Le monde sous-marin demeure relativement opaque aux moyens de détection reposant sur l'utilisation des ondes électromagnétiques. En effet, ces ondes étant fortement atténuées par le milieu marin, les portées de détection se révèlent être trop faibles pour la plupart des applications visées. La distance à partir de laquelle un objet peut être analysé varie de quelques mètres dans le cas de senseurs optiques à quelques dizaines de mètres pour des capteurs magnétiques. Seules les ondes de vibrations mécaniques permettent la transmission d'un signal dans le milieu marin sans subir une atténuation trop importante, et ce, dans une large bande de fréquences. Historiquement qualifiées d'*ondes acoustiques*, leur étude a donné naissance à une nouvelle discipline scientifique : l'acoustique sous-marine. Elle a permis la conception de différents systèmes exploitant ce phénomène ondulatoire. Un détecteur d'iceberg, constitué autour d'un haut-parleur sous-marin, a été mis au point en 1912-1914 à la suite du naufrage du Titanic. Puis, ce fut l'apparition de l'ASDIC dont le rôle était de protéger les convois de navires alliés contre les sous-marins allemands pendant la deuxième guerre mondiale. Le SONAR (SOund Navigation And Ranging) constitue l'aboutissement des recherches menées dans ce domaine. Ce système permet l'émission, la réception et le traitement du signal dans le but d'acquérir toute sorte d'informations sur le milieu marin. Les applications liées au SONAR sont multiples :

- détection, localisation et reconnaissance d'objets de petite taille posés sur le fond à l'aide de SONAR haute fréquence [65, 94] ;
- détection, classification et suivi de sous-marins ou de bâtiments [12] ;
- mesure de l'altimétrie par rapport au fond marin grâce aux sondeurs [88] ;
- cartographie des fonds marins [107] ;
- localisation des bancs de poissons à l'aide des SONAR de pêche.

Le principe du SONAR demeure performant même si le milieu de propagation change de nature. On retrouve ce principe dans l'échographie qui est un procédé d'exploration non invasif du corps humain [46], ou encore dans l'industrie métallurgique qui utilise ce concept dans le cadre du contrôle non destructif de pièces industrielles [8].

L'exploitation des informations recueillies par un système de détection peut être facilitée selon la manière dont celles-ci sont présentées à un opérateur. La représentation sous forme d'images constitue un bon compromis, car elle permet d'analyser un nombre important de données en un temps relativement court.

1.2 Imagerie SONAR

Le SONAR haute fréquence apporte une réponse efficace aux problèmes liés à la détection de petits objets reposant sur les fonds marins. Après l'émission d'une onde sonore, la détection se fonde sur l'apparition d'un signal réfléchi par l'objet ou d'une interférence générée par la présence de cet objet. Encore faut-il que les dimensions et la position de l'objet soient compatibles avec les capacités de détection du SONAR. Nous abordons là les questions qui se posent lors de la conception d'un système SONAR et qui conduisent à l'élaboration de SONAR spécialisés dans des tâches bien définies :

- le SONAR détecteur qui décèle la présence d'un objet ;
- le SONAR classifieur qui permet l'analyse d'un objet mais avec une portée de détection plus faible ;
- la caméra acoustique qui conduit à une reconnaissance de l'objet à très courte portée.

Les principales différences résident dans les fréquences d'émission et de réception (donc dans les tailles d'antennes), le mode de visualisation du milieu (vision sectorielle, panoramique ou encore latérale), et l'architecture du système. Les images acquises par ces différents SONAR permettent de satisfaire les objectifs initialement fixés [98].

1.2.1 Architecture d'un SONAR

L'étude de l'architecture d'un SONAR actif montre que celui-ci est constitué de plusieurs modules. Sans détailler le fonctionnement de chacun d'entre eux, nous nous attacherons à souligner les caractéristiques des traitements qu'ils effectuent et qui ont une incidence directe sur la façon dont le signal reçu est visualisé [12].

Le module d'émission A l'aide d'un oscillateur, d'un modulateur, d'un préamplificateur de puissance, ce module génère l'émission d'une impulsion de quelques microsecondes, modulée à une fréquence de l'ordre de 500 kHz (entre 300 et 800 kHz) avec une récurrence de quelques millisecondes pour un SONAR classificateur. C'est la modification de la valeur de ces paramètres qui influence directement les performances du SONAR en termes de portée de détection et de résolution. Par exemple, lorsque l'on augmente la fréquence d'émission, on améliore la résolution (distance minimale devant séparer deux objets pour que le SONAR puisse les distinguer). En contrepartie, la portée de détection diminue, car le coefficient d'absorption du milieu marin augmente avec la fréquence. Ce signal doit être transmis au milieu marin, c'est le rôle de l'antenne d'émission.

L'antenne SONAR Le module antenne d'un SONAR est souvent constitué de deux séries de transducteurs ou capteurs : l'antenne d'émission et l'antenne de réception. Chacune est constituée de transducteurs piézo-électriques dont le rôle est de transformer un signal électrique en une onde acoustique qui se propagera dans le canal marin et inversement. Les performances d'une antenne peuvent être représentées à l'aide des diagrammes de directivité en azimut qui est l'angle θ_0 formé par l'axe de propagation du signal et un axe de référence dans un plan horizontal (cf. figure 1.1).

Chaque diagramme de directivité comporte un lobe principal et des lobes secondaires de moindre amplitude qui traduisent le pouvoir de résolution du SONAR :

- l'angle d'ouverture d'une antenne se définit comme le double de l'angle correspondant à une chute d'intensité de 3 dB par rapport à la référence 0 dB qui correspond à l'intensité maximale émise dans l'axe de l'émission. Cet angle d'ouverture fixe la résolution en azimut pour une utilisation en mode réception de l'antenne. En effet, deux sources séparées angulairement de moins de $2\theta_3$ (cf. figure 1.1) ne pourront pas être distinguées. Plus le lobe principal sera fin et meilleure sera la résolution.
- les lobes secondaires ont un effet dégradant dans le traitement d'antenne. En effet, leur présence conduit à une remontée du niveau de bruit et entraîne une perte de précision en localisation et une mauvaise définition des contours des différents objets posés sur le fond marin.




FIG. 1.1 – Représentation des angles d'ouverture ($2\theta_3$ et $2\varphi_3$) d'une antenne SONAR.

Le diagramme de directivité dépend de la forme de l'antenne, du nombre de capteurs, de leur disposition et de la fréquence de travail. Une augmentation de cette fréquence entraîne une diminution de l'ouverture et malheureusement une remontée du niveau des lobes secondaires, et surtout une atténuation plus importante par le milieu marin de l'onde acoustique émise. On est donc obligé d'établir un compromis entre l'ouverture de l'antenne et la portée de détection, ceci en fonction de l'application retenue.

Le pouvoir de résolution en distance, distance minimale devant séparer deux objets situés sur l'axe de propagation de l'onde, dépend de la durée de l'impulsion T . Il s'obtient par la formule $cT/2 \sin \varphi$ où c représente la célérité du son dans l'eau de mer, de l'ordre de 1500 m/s, et φ le site de l'émission. Là encore, une augmentation de la durée d'impulsion, afin d'améliorer le gain de traitement, conduit à une perte de résolution en distance. Les valeurs retenues pour les caractéristiques de l'émission SONAR figent les dimensions de la *cellule de résolution* du SONAR (cf. figure 1.2).

Le module de réception Ce module doit assurer :

- une amplification des signaux issus des transducteurs de l'antenne de réception. Cette amplification a pour but de conserver un niveau du signal reçu relativement constant en fonction de la portée. En effet, au cours des trajets aller et retour dans le milieu marin, l'onde subit des pertes par absorption et par divergence géométrique, pertes qui sont proportionnelles à la distance objet-SONAR. En outre, divers bruits viennent se superposer au signal, bruit ambiant de la mer, bruit de réverbération de volume, bruit propre généré par le bâtiment porteur du SONAR et bruit électronique de la chaîne de traitements ;
- une régulation de la dynamique d'entrée par une Commande Automatique de Gain (CAG) ;
- un filtrage suivi d'une opération de détection-intégration afin de conserver l'enveloppe du signal utile ;
- le codage des signaux avant la phase de visualisation.

Ces différentes opérations entraînent de nombreuses perturbations du signal et compliquent singulièrement toute tentative de modélisation des dégradations subies par le signal dans le SONAR.




FIG. 1.2 – Cellule de résolution d'un SONAR. La partie grisée représente la surface du fond marin explorée par l'onde émise au cours d'une impulsion de durée T .

1.2.2 Processus de formation des images

Les capteurs utilisés dans une antenne SONAR mesurant des variations de pression, il est d'usage d'étudier le module de l'amplitude complexe du signal délivré [15], et non l'intensité du signal comme en imagerie RADAR [67]. Le principe de formation d'une image est basé sur le découpage d'une région du fond marin en surfaces élémentaires ou cellules de résolution. Une voie est formée dans une direction donnée et correspond à l'exploration spatiale de la zone à examiner. Puis, un échantillonnage temporel du signal réverbéré par le fond marin permet d'obtenir l'amplitude de ce signal en fonction de la distance. Par formation électronique d'un grand nombre de voies, l'ensemble de la zone est explorée secteur par secteur (cf. figure 1.3).




FIG. 1.3 – Exploration d'une zone du fond marin, secteur par secteur, à l'aide d'un SONAR détecteur/classificateur de coque. Le balayage de chaque secteur est assuré par la formation électronique d'un grand nombre de voies [98].

Une autre solution pour explorer toute une zone consiste à ne former qu'un petit nombre de voies très directives et à déplacer le SONAR selon une direction perpendiculaire à l'axe d'émission. C'est la solution retenue pour le SONAR à balayage latéral remorqué (cf. figure 1.4).




FIG. 1.4 – Exploration d'une zone du fond marin à l'aide d'un SONAR à balayage latéral remorqué. C'est le déplacement du SONAR qui assure le balayage de la zone par juxtaposition d'un petit nombre de voies très directives (<http://chartmaker.ned.noaa.gov/ocs/text/wrecks.html>).

1.3 Détection d'objets

De nombreux perfectionnements ont été apportés afin d'améliorer cette détection qui s'effectue quelquefois dans des conditions difficiles pour des objets de petite taille, en présence de revêtement anéchoïde qui réduit la valeur de l'indice de réverbération des objets, ou pour la localisation des objets dans des eaux peu profondes, ... Ces améliorations ont permis de développer deux catégories de SONAR s'appuyant sur des principes de détection différents.

Le SONAR détecteur Cette méthode de détection repose sur la recherche de l'écho réfléchi par un objet. Ce sonar est chargé de repérer l'écho d'un objet au milieu du bruit [48]. A faible distance du SONAR, ce bruit est généré par la réverbération du fond alors que dans une zone plus lointaine, c'est le bruit électronique de la chaîne de traitement du SONAR qui devient prépondérant. Dans les deux cas, pour assurer une détection de l'écho, il faut que les contrastes entre l'écho et la réverbération de fond et entre l'écho et le bruit électronique soient suffisants. Une opération de seuillage adaptatif permet de mettre en évidence la présence de l'écho dans une zone donnée.

Le SONAR classificateur La qualité d'un écho ne conduit que très rarement à une classification. Quelquefois, cet écho est quasi inexistant et donc inexploitable pour un objet possédant un très faible indice de réverbération. Aussi est née l'idée d'utiliser la forme de l'ombre produite par un objet posé sur le fond et insonifié par une onde acoustique (cf. figure 1.5). La zone située derrière l'objet, par rapport au SONAR, n'est pas insonifiée en raison de la présence de cet objet qui intercepte l'onde lors de sa propagation. Cette ombre caractérise une absence de réverbération de fond pendant le temps mis par l'onde pour parcourir cette zone. Le signal reçu en provenance de cette zone est constitué du bruit de réverbération de volume, également d'un peu de signal issu des lobes secondaires en particulier sur les bords de la zone d'ombre, et de bruit électronique en provenance de la chaîne de traitements. Si on trace l'évolution du signal reçu en fonction du temps pour une voie donnée, on observe :

- tout d'abord une amplitude faible associée à la réverbération de volume. Ce signal représente les interférences générées par l'onde sonore avec le milieu marin, lors de son trajet entre l'antenne et le fond ;
- une augmentation d'amplitude correspondant à la rétrodiffusion de l'onde incidente par le fond ;
- un maximum associé à l'écho sur l'objet ;
- une chute brutale de l'amplitude relative à la zone de l'ombre portée, mélange de bruit de réverbération de volume et de bruit électronique dans le cas idéal où l'antenne ne possède pas de lobes secondaires ;
- enfin, une amplitude pratiquement nulle correspondant à la fin du signal rétrodiffusé.

Ce principe de classification, qui est également appliqué au SONAR à balayage latéral, permet d'obtenir d'excellents résultats en terme de détection et de reconnaissance d'objets.




FIG. 1.5 – *Principe de la classification sur ombre. Formation d'une ombre acoustique dont l'analyse permettra de détecter puis d'identifier l'objet.*

1.4 Bruit en imagerie SONAR

1.4.1 Réverbération de fond et bruit de speckle

La zone de réverbération de fond d'une image SONAR possède un aspect granulaire assez particulier. Cette mauvaise qualité d'image est inhérente au système SONAR et plus généralement à tout système d'émission-réception cohérente. Connue sous le nom de speckle, ce bruit a fait l'objet de nombreux travaux en imagerie laser à lumière cohérente [39, 40], en imagerie radar à ouverture synthétique [3, 31, 61, 66, 89], ou encore en imagerie médicale [15, 47, 60, 92, 101, 102]. Le bruit de speckle apparaît lorsqu'une onde électromagnétique ou acoustique illumine une surface constituée d'un grand nombre de diffuseurs dont les dimensions sont petites devant la longueur d'onde incidente. Chaque diffuseur se comporte alors comme une source émettant une onde, de même longueur d'onde mais dont l'amplitude, la phase et la direction sont aléatoires. L'antenne de réception perçoit un signal qui est le résultat de l'interférence de toutes les ondes réfléchies par les diffuseurs

présents dans la cellule de résolution. Dans le cas où les deux hypothèses suivantes sont vérifiées, à savoir ;

1. à l'intérieur d'une cellule de résolution, le fond marin est constitué d'un grand nombre de diffuseurs indépendants et spatialement répartis de façon aléatoire ;
2. à l'échelle de la cellule de résolution, le fond marin est constitué de zones homogènes ce qui suppose une rugosité faible du fond marin,

la distribution des niveaux de gris des pixels, associée à la partie dite réverbération de fond, se modélise par une loi de Rayleigh. Elle traduit le bruit de speckle visible sur les images acoustiques [39]. Compte tenu des fréquences utilisées, des dimensions de la cellule de résolution, de quelques centimètres carrés à quelques dizaines de centimètres carrés, et de la rugosité des différentes zones de fond marin, cette modélisation est classique et correspond à de nombreuses situations en imagerie acoustique. Cependant ce modèle n'est pas toujours réaliste et pour certains types de fond comme des rides de sable grossier ou des fonds rocheux, ou lorsque la dimension des rugosités du fond devient du même ordre de grandeur que les dimensions de la cellule de résolution, en particulier dans le cas du SONAR à ouverture synthétique, ou encore lorsque le SONAR est exploité dans des eaux très peu profondes, d'autres modèles de bruit, comme le mélange de lois de Weibull, doivent être envisagés.

1.4.2 Bruit associé aux ombres acoustiques

L'ombre située derrière un objet sur une image SONAR, correspond à une absence de réverbération de fond. Le niveau du signal reçu est donc très faible en comparaison du signal correspondant au bruit de speckle. Toutefois, ce signal n'est pas nul, et il présente, malgré tout, des variations significatives. Celles-ci ont plusieurs origines :

- le bruit électronique de la chaîne de réception s'ajoute au signal reçu par l'antenne. Le niveau relatif de ce bruit augmente au fur et à mesure que l'on s'éloigne de l'antenne ;
- la présence de lobes secondaires et les dimensions de la cellule de résolution induisent une augmentation du niveau de bruit dans les zones frontières entre le fond et les ombres, par duplication du bruit de speckle provenant de la réverbération de fond. Le nombre de pixels affectés par le bruit de speckle provenant des imperfections de l'antenne sera, en proportion, plus important si la zone d'ombre est de petite dimension.

Le bruit associé à la partie correspondant aux ombres dans l'image est donc un mélange de ces deux types de bruit.

1.5 Conclusion

Nous avons abordé, dans ce chapitre, les processus d'acquisition et de formation des images du monde sous-marin à l'aide d'un SONAR haute fréquence. Ceci nous a conduit à étudier les différentes méthodes de détection des objets reposant sur ces fonds, et à exposer les propriétés des bruits qui s'appliquent sur les différentes régions d'une image SONAR. Une estimation plus précise de la nature de ce bruit, nature des lois, proportion du mélange des distributions et paramètres associés à ces lois, sera abordé dans le chapitre suivant. Elle sera exploitée dans notre modèle de segmentation non-supervisée des images SONAR.

Première partie

Estimation des paramètres

Introduction

Une segmentation basée sur une stratégie bayésienne requiert la connaissance de certains paramètres de la loi jointe $P_{X,Y}(x, y)$. X représente ici le champ des étiquettes ou les informations que l'on cherche à extraire des observations (i.e., l'image segmentée) et Y le champ des observations ou informations dont on dispose pour effectuer l'analyse (i.e., l'image numérique ou l'ensemble des pixels de l'image). Pour être plus précis, mais sans entrer dans les détails du formalisme markovien auxquels on pourra se reporter [7], ces paramètres sont

- ceux associés à la loi $P_{Y/X}(y/x)$ qui caractérisent le modèle du bruit. Cette probabilité liée au terme d'énergie d'attache aux données du modèle markovien permet de modéliser le lien entre les étiquettes et les observations. Une bonne segmentation par une approche markovienne nécessite donc, dans un premier temps, une connaissance très précise de la nature du bruit qui s'applique sur l'image (i.e., nature des lois associées à chacune des classes existant dans l'image et paramètres associés à ces lois). Ce problème d'estimation revient à identifier un mélange de lois statistiques et à estimer les paramètres associés à ces lois d'après la distribution des intensités observées.
- ceux associés à la loi $P_X(x)$ qui caractérise et modélise les propriétés du champ d'étiquettes et que l'on définit dans une segmentation markovienne comme étant une distribution de Gibbs. C'est l'estimation de ces paramètres (et plus précisément des paramètres associés à chaque clique) qui va permettre d'introduire des contraintes génériques qui, dans le processus de segmentation, traduisent les propriétés locales et globales du champ d'étiquettes (propriétés géométriques, homogénéité, variabilités spatiales ...) que l'on cherche à obtenir.

L'estimation de tous ces paramètres est entièrement automatique si elle est faite à partir de $Y = y$, l'image numérique à segmenter. La solution de ce problème d'estimation permet la conception d'algorithmes de segmentation non supervisés.

Dans cette partie, nous nous intéressons à l'estimation des paramètres du modèle markovien pour une segmentation des images SONAR en deux classes (*ombre/réverbération*). Le premier chapitre concerne l'estimation des paramètres du modèle du bruit. Nous présentons et comparons deux types de modélisation : une reposant sur un mélange de lois différentes (dans lequel on utilise une loi gaussienne pour modéliser la répartition des niveaux de gris situés dans une zone d'ombre et une loi de Rayleigh pour prendre en compte le bruit de speckle et pour modéliser la répartition des niveaux de gris situés dans la zone de réverbération) et une autre, plus générale, reposant sur un mélange de lois de Weibull. Nous comparons, sur des images SONAR réelles et synthétiques, les résultats obtenus par les algorithmes d'estimation classiques tels que le SEM (*Stochastique Estimation Maximization*), l'EM (*Expectation Maximization*) ou l'ECI (*Estimation Conditionnelle Itérative*). Une solution originale au problème de l'initialisation de ces algorithmes d'estimation itératifs est notamment présentée. Le second chapitre est consacré à l'estimation des paramètres du modèle du champ d'étiquettes. Dans ce chapitre, nous présentons aussi notre méthode d'estimation permettant d'estimer conjointement les deux types de paramètres au sens du Maximum de Vraisemblance pour le modèle du bruit et au sens des moindres carrés pour le modèle du champ d'étiquettes.

Chapitre 1

Estimation des paramètres du modèle de bruit

1.1 Introduction

Différents travaux [91, 98] ont mis en évidence l'intérêt d'une modélisation du bruit en imagerie SONAR par deux lois de nature différente. Dans ce modèle de bruit, la répartition des niveaux de gris situés dans une zone d'ombre est modélisée par une loi normale, et celle associée au bruit de speckle (ou aux zones de réverbération), par une loi de Rayleigh décalée. Cette modélisation du bruit de speckle par une loi de Rayleigh est classique et correspond à de nombreuses situations en imagerie acoustique [39]. De même, une loi gaussienne est une loi appropriée pour décrire la répartition des niveaux de gris situés dans une zone d'ombre si on considère (en première approximation) que le bruit situé dans cette région est essentiellement de nature électronique. Cependant, cette modélisation du bruit de speckle par une loi de Rayleigh n'est pas toujours adéquate, en particulier lorsque la dimension des rugosités du fond marin devient du même ordre de grandeur que les dimensions de la cellule de résolution du SONAR (c'est le cas pour certains types de fonds marins comme les rides de sable grossier ou les fonds rocheux). De plus, la modélisation du bruit à l'intérieur des zones d'ombre doit prendre en compte l'information apportée par les lobes secondaires de l'antenne SONAR. C'est pour ces raisons que d'autres modèles de bruit, plus généraux, doivent être envisagés. Parmi les nombreuses lois existantes, nous retenons la distribution de Weibull pour laquelle le réglage des paramètres offre une très grande variabilité de modélisation possible.

Dans ce chapitre, nous nous intéressons à l'estimation des paramètres du modèle du bruit. Dans le deuxième paragraphe, nous rappelons les différentes façons d'envisager une segmentation non supervisée et les différents types d'algorithmes existants. Le troisième paragraphe est consacré à l'étude des estimateurs MV des paramètres du modèle du bruit lorsque x est supposé observable (estimateur des données complètes), dans le cas du mélange de lois gaussiennes, de Rayleigh ou de Weibull. Dans le quatrième paragraphe, nous présentons les algorithmes classiques qui permettent d'estimer ces paramètres au sens des données incomplètes (dans ce cas, x est non observable) et le principe de la *segmentation courante*. Nous rappelons rapidement le principe de ces méthodes, précisons la possibilité de leur application dans le cas de l'estimation d'un mélange de distributions et décrivons les calculs de ré-estimation des paramètres pour nos deux types de modélisation de bruit. Les paragraphes suivants sont consacrés aux relations existant entre ces différents algorithmes et aux résultats expérimentaux obtenus sur des images SONAR synthétiques et réelles.

1.2 Étude bibliographique

De nombreuses méthodes ont été proposées pour réaliser une segmentation markovienne non supervisée. Celles-ci peuvent se regrouper en trois principales catégories.

- La première divise le problème de la segmentation non supervisée en deux étapes: une étape d'*estimation des paramètres* du modèle markovien à partir du champ y , et une étape de *segmentation* utilisant les

paramètres estimés précédemment.

- La seconde consiste à résoudre simultanément les problèmes d'*estimation des paramètres* du modèle markovien et de *segmentation* (méthode dite de *segmentation courante*).
- La troisième comprend des méthodes hybrides qui associent ces deux types de stratégie.

Segmentation en deux étapes

Parmi les méthodes utilisées pour estimer les paramètres du modèle à partir du champ y , le seul observable, on peut citer celles qui utilisent l'histogramme de l'image. Plus précisément, on peut citer celles basées sur la transformée de Fourier ou les méthodes polynomiales [14] ou encore celles qui utilisent l'analyse géométrique des domaines concaves du mélange [53, 87] (méthode de l'histogramme cumulé). Ces algorithmes sont très efficaces dans le cas d'un mélange gaussien où le caractère multimodal de l'histogramme de l'image apparaît, même faiblement, mais sont très peu fiables lorsque les lois sont plus mélangées (i.e., lorsque le caractère multimodal de l'histogramme n'apparaît plus). De plus, même si une justification mathématique a été trouvée pour le cas particulier du mélange de distributions gaussiennes, ces algorithmes ne peuvent s'appliquer, en toute rigueur, à des lois d'autre nature (lois de Rayleigh ou de Weibull par exemple) ou pour un mélange de lois de nature différente.

Parmi les méthodes plus récentes qui utilisent non plus l'histogramme mais le champ d'observation y (i.e., l'ensemble des pixels de l'image), on peut citer l'algorithme EM [29] (*Expectation Maximization*) qui est utilisé pour calculer ces paramètres au sens du MV quand les observations sont vues comme étant des données incomplètes, ou encore l'algorithme SEM (*Stochastic Estimation Maximization*) [17, 70], variante stochastique de l'algorithme EM. Ces algorithmes supposent les variables aléatoires X_i indépendantes entre elles (algorithmes locaux) et ne prennent donc pas en compte le caractère markovien du champ d'étiquettes. Parmi les méthodes qui exploitent les informations *a priori* que l'on a sur X (méthodes globales), on peut citer l'EM Gibbsien (EMG) [18], l'EM global proposé dans [110] ou encore la procédure générale d'estimation dite Estimation Conditionnelle Itérative ECI [86] qui assure la meilleure approximation des paramètres du mélange au sens de l'erreur quadratique moyenne. Un autre algorithme adaptatif est présenté dans [105], basé sur l'algorithme du gradient stochastique. Cette méthode est différente de l'ECI mais la démarche générale est la même : la valeur mise à jour des paramètres est obtenue à partir de y , et de réalisations tirées selon la loi *a posteriori* $P_{X/Y}$ pour la valeur courante des paramètres.

Segmentation courante

Pour les méthodes de type *segmentation courante*, les auteurs proposent la résolution simultanée des problèmes d'*estimation des paramètres* et de *segmentation*. Parmi les méthodes proposées, on peut citer celle du Recuit Simulé Adaptatif (RSA) [55, 63]. Le principe de cet algorithme de segmentation non supervisée consiste à interrompre régulièrement le déroulement du recuit simulé et à utiliser la valeur courante x du champ X afin de ré-estimer tous les paramètres du modèle. Un algorithme itératif similaire au RSA est présenté dans [7] où la suite des réalisations de X est donnée par une méthode de relaxation déterministe : l'ICM. Version simplifiée du RSA, cet ICM Adaptatif (ICMA) n'est cependant pas assuré de converger pour la suite des paramètres obtenus vers le maximum de vraisemblance et pour celle de la suite de champs d'étiquettes obtenue vers une solution du MAP. Ces deux derniers algorithmes utilisent la valeur courante du champ x , à chaque itération, afin de ré-estimer tous les paramètres du modèle par une estimation au sens du MV ainsi que le résultat de la précédente segmentation comme initialisation pour la suivante.

Méthodes hybrides

Afin de conforter le procédé de segmentation, certains auteurs associent les deux méthodes précédentes : l'estimation des paramètres à partir du champ y , le seul observable, dans une première étape est utilisée pour réaliser une première segmentation de l'image. Un algorithme de segmentation adaptatif est ensuite

utilisé à partir de cette initialisation. C'est le cas de [104] où les auteurs utilisent l'algorithme EM pour l'estimation des paramètres du modèle du bruit. Les estimations sont ensuite utilisées pour réaliser une première segmentation de l'image (au sens du MV). Cette segmentation initiale et cette première estimation des paramètres sont ensuite utilisées afin d'initialiser un ICMA.

1.3 Estimateur MV des données complètes

X représente le champ des étiquettes et Y le champ des observations (i.e., ensemble des N pixels de l'image). Supposons que X soit connu (ou *observable*) et que l'étiquette X_i soit la même pour chaque Y_i de Y (i.e., il existe une seule classe dans l'image). Soit donc $Y = (Y_1, Y_2, \dots, Y_N)$, N variables aléatoires, indépendantes et identiquement distribuées selon une certaine loi $L(y; \Phi_y)$ de paramètre Φ_y et $y = (y_1, y_2, \dots, y_N)$, une réalisation particulière de Y . L'estimation de Φ_y au sens du MV consiste à trouver $\hat{\Phi}_y$, tel que :

$$\hat{\Phi}_y = \arg \max_{\Phi_y} \{ \ln P_{Y/\Phi_y}(y/\Phi_y) \} \quad (1.1)$$

où $\ln P_{Y/\Phi_y}(y/\Phi_y)$ est la fonction de log-vraisemblance, avec $\mathcal{L}(\Phi_y) \triangleq P_{Y/\Phi_y}(y/\Phi_y)$, la vraisemblance.

1.3.1 Loi gaussienne

Lorsque $L(y; \Phi_y)$ est une loi gaussienne $\mathcal{N}(y; \Phi_y)$ de paramètre $\Phi_y = (\mu, \sigma^2)$, ces estimateurs sont simplement la moyenne et la variance empirique (estimateurs naturels) :

$$\hat{\mu}_{MV} = \frac{1}{N} \sum_{i=1}^N y_i \quad (1.2)$$

$$\hat{\sigma}_{MV}^2 = \frac{1}{N-1} \sum_{i=1}^N (y_i - \hat{\mu}_{MV})^2 \quad (1.3)$$

1.3.2 Loi de Rayleigh

Lorsque $L(y; \Phi_y)$ est une loi de Rayleigh décalée [91], $\mathcal{R}(y; \Phi_y)$ de paramètre $\Phi_y = (min, \alpha^2)$:

$$\mathcal{R}(y; \Phi_y) = \left(\frac{y - min}{\alpha^2} \right) \exp \left(-\frac{(y - min)^2}{2\alpha^2} \right) \quad (1.4)$$

La fonction de log-vraisemblance s'écrit :

$$\ln \mathcal{L}(\Phi_y) = \ln P_{Y/\Phi_y}(y/\Phi_y) \quad (1.5)$$

$$= \ln \left\{ \prod_{i=1}^N \left[\left(\frac{y_i - min}{\alpha^2} \right) \exp \left(-\frac{(y_i - min)^2}{2\alpha^2} \right) \right] \right\} \quad (1.6)$$

$$= \sum_{i=1}^N \ln(y_i - min) - N \ln \alpha^2 - \frac{1}{2\alpha^2} \sum_{i=1}^N (y_i - min)^2 \quad (1.7)$$

avec $(min < y_i) \forall i$. Pour déterminer $\widehat{min}_{MV}$ et $\hat{\alpha}_{MV}^2$ (valeurs qui maximisent la fonction de vraisemblance), on résout simultanément les deux équations suivantes :

$$\frac{\partial \ln \mathcal{L}(\Phi_y)}{\partial \alpha^2} = 0 \quad (1.8)$$

$$\frac{\partial \ln \mathcal{L}(\Phi_y)}{\partial \min} = 0 \quad (1.9)$$

$\widehat{\min}_{MV}$ et $\hat{\alpha}_{MV}^2$ sont alors solutions du système d'équations :

$$-2N + \frac{1}{\hat{\alpha}^2} \sum_{i=1}^N (y_i - \widehat{\min})^2 = 0 \quad (1.10)$$

$$-\sum_{i=1}^N \frac{1}{(y_i - \widehat{\min})} + \frac{1}{\hat{\alpha}^2} \sum_{i=1}^N (y_i - \widehat{\min}) = 0 \quad (1.11)$$

avec $(\min < y_i) \forall i$. $\widehat{\min}_{MV}$ solution de ce système est en fait très légèrement inférieur à $y_{\min}$ (intensité minimum de l'échantillon y). Pour cette raison et pour permettre aux pixels de niveau de gris égal à $y_{\min}$ d'avoir une probabilité non nulle d'apparition, nous prendrons l'estimateur suivant :

$$\widehat{\min}_{MV} \approx \hat{y}_{\min} - 1 \quad (1.12)$$

et par la suite nous poserons $\tilde{y}_i = (y_i - \widehat{\min}_{MV})$. Après simplification, l'équation (1.10) donne $\hat{\alpha}_{MV}^2$:

$$\hat{\alpha}_{MV}^2 = \frac{\sum_{i=1}^N \tilde{y}_i^2}{2N} \quad (1.13)$$

On pourra vérifier en annexe A que l'estimateur $\hat{\alpha}_{MV}^2$ possède de bonnes propriétés asymptotiques.

1.3.3 Loi de Weibull


Le principal intérêt de cette loi réside dans sa flexibilité. Ainsi pour certaines valeurs d'un de ses paramètres (le paramètre de forme C), on retrouve la loi exponentielle ($C = 1$) et la loi de Rayleigh ($C = 2$). Cette propriété explique l'utilisation qu'en font les statisticiens pour modéliser des échantillons de variables aléatoires exponentielles dont les critères de dépendances ne sont pas pleinement vérifiés [25]. Pour notre application, cette flexibilité est aussi particulièrement intéressante et permet de modéliser plus efficacement la distribution du bruit de speckle (cf. 1.3.4 et [25]). Notons aussi que cette loi est utilisée dans le cas particulier des images RADAR de la surface de la mer [25]. Elle est définie par :

$$\mathcal{W}(y; \min, C, \alpha) = \frac{C}{\alpha} \left(\frac{(y - \min)}{\alpha} \right)^{C-1} \exp \left(- \frac{(y - \min)^C}{\alpha^C} \right) \quad (1.14)$$

avec $y > \min$, $\alpha > 0$ et $C > 0$. α et C sont respectivement un paramètre d'échelle et un paramètre de forme strictement positifs. $\min$ est un paramètre de décalage qui permet de prendre en compte les différents processus de formation de l'image SONAR (contrôle automatique de gain, offset ...) [91]. Nous avons représenté en figure 1.1 le tracé de cette loi pour différentes valeurs du facteur de forme C . Dans cet exemple $\alpha = 1$ et $\min = 0$. La méthode du MV permet d'obtenir une estimation des paramètres $\min$, α , et C pour un échantillon y donné. Du fait de l'indépendance des différentes v.a. y_i de l'échantillon y , la fonction de vraisemblance s'écrit :

$$\mathcal{L}(\Phi_y) = P_{Y/\Phi_y}(y/\Phi_y) \quad (1.15)$$

$$= \left(\frac{C}{\alpha^C} \right)^N \prod_{i=1}^N \left[(y_i - \min)^{C-1} \exp \left(- \frac{(y_i - \min)^C}{\alpha^C} \right) \right] \quad (1.16)$$

FIG. 1.1 – *Lois de Weibull pour différentes valeurs du facteur de forme C .*

Le logarithme de l'expression précédente donne la fonction de log-vraisemblance :

$$\ln \mathcal{L}(\Phi_y) = \ln P_{Y/\Phi_y}(y/\Phi_y) \quad (1.17)$$

$$= N \ln C + (C-1) \sum_{i=1}^N \ln(y_i - \min) - NC \ln \alpha - \frac{1}{\alpha^C} \sum_{i=1}^N (y_i - \min)^C \quad (1.18)$$

avec $y_i > \min \forall i$, $\alpha > 0$ et $C > 0$. Pour déterminer $\widehat{\min}_{MV}$, $\hat{\alpha}_{MV}$ et $\hat{C}_{MV}$ (valeurs qui maximisent la fonction de vraisemblance), on résout simultanément les trois équations suivantes :

$$\frac{\partial \ln \mathcal{L}(\Phi_y)}{\partial \min} = 0 \quad (1.19)$$

$$\frac{\partial \ln \mathcal{L}(\Phi_y)}{\partial \alpha} = 0 \quad (1.20)$$

$$\frac{\partial \ln \mathcal{L}(\Phi_y)}{\partial C} = 0 \quad (1.21)$$

Comme pour la loi de Rayleigh, $\widehat{\min}_{MV}$ déterminé par la première équation du système est en fait très légèrement inférieur à $y_{\min}$ (intensité minimum de l'échantillon y) et nous prendrons l'estimateur suivant :

$$\widehat{\min}_{MV} \approx \hat{y}_{\min} - 1 \quad (1.22)$$

et par la suite nous poserons $\tilde{y}_i = (y_i - \widehat{\min}_{MV})$. $\hat{\alpha}_{MV}$ et $\hat{C}_{MV}$ sont alors solutions du système d'équations :

$$-N + \frac{1}{\hat{\alpha}^{\hat{C}}} \sum_{i=1}^N \tilde{y}_i^{\hat{C}} = 0 \quad (1.23)$$

$$\frac{N}{\hat{C}} + \sum_{i=1}^N \ln \tilde{y}_i - N \ln \hat{\alpha} - \sum_{i=1}^N \left(\frac{\tilde{y}_i}{\hat{\alpha}} \right)^{\hat{C}} \ln \left(\frac{\tilde{y}_i}{\hat{\alpha}} \right) = 0 \quad (1.24)$$

Après simplification, l'équation précédente donne $\hat{\alpha}_{MV}$:

$$\hat{\alpha}_{MV} = \left(\frac{1}{N} \sum_{i=1}^N \tilde{y}_i^{\hat{C}_{MV}} \right)^{\frac{1}{\hat{C}_{MV}}} \quad (1.25)$$

Par contre on ne peut pas obtenir de forme explicite pour l'estimateur $\hat{C}_{MV}$. En utilisant l'équation (1.25), l'expression (1.23) se simplifie un peu et $\hat{C}_{MV}$ est solution de l'équation :

$$\frac{\sum_{i=1}^N (\tilde{y}_i^{\hat{C}_{MV}} \ln \tilde{y}_i)}{\sum_{i=1}^N \tilde{y}_i^{\hat{C}_{MV}}} - \frac{1}{\hat{C}_{MV}} = \frac{1}{N} \sum_{i=1}^N \ln \tilde{y}_i \quad (1.26)$$

Cette équation ne peut se résoudre numériquement que par approximations successives. Cette résolution peut se faire par une méthode numérique classique (itérations successives, dichotomie, méthode de Newton ou encore de Lagrange). Dans notre cas, la démarche à effectuer pour obtenir rapidement et efficacement une bonne estimation de $\hat{C}_{MV}$ est grandement facilitée car l'équation (1.26) peut se mettre sous la forme $F(\hat{C}_{MV}) = \hat{C}_{MV}$:

$$\hat{C}_{MV} = \frac{N \sum_{i=1}^N \tilde{y}_i^{\hat{C}_{MV}}}{N \sum_{i=1}^N (\tilde{y}_i^{\hat{C}_{MV}} \ln \tilde{y}_i) - (\sum_{i=1}^N \ln \tilde{y}_i) (\sum_{i=1}^N \tilde{y}_i^{\hat{C}_{MV}})} \quad (1.27)$$

$\hat{C}_{MV}$ peut se résoudre par la méthode des suites récurrentes dont nous rappelons le principe. Soit la suite récurrente :

$$C_1, C_2 = F(C_1), \dots, C_n = F(C_{n-1}) \quad (1.28)$$

Si cette suite converge vers une limite l , cette limite est alors solution de l'équation $l = F(l)$ (justifié par la formule des accroissements finis). Inversement si $l = F(l)$ possède une solution unique (c'est notre cas puisque $\hat{C}_{MV}$ est la racine unique de l'équation $F(\hat{C}_{MV}) = \hat{C}_{MV}$), alors cette solution est aussi la valeur de convergence de la suite récurrente $\hat{C}_n = F(\hat{C}_{n-1})$. La convergence de la suite C_n est assurée car l'unicité de l'estimateur MV implique que $F(\cdot)$ est une fonction monotone. $\hat{C}_{MV}$ est donc donné par la relation suivante :

$$\hat{C}_{MV} = \lim_{n \rightarrow \infty} C_n \quad (1.29)$$

avec C_n , une suite définie par la relation de récurrence $C_n = F(C_{n-1})$ et $F(x)$ défini par :

$$F(x) = \frac{N \sum_{i=1}^N \tilde{y}_i^x}{N \sum_{i=1}^N (\tilde{y}_i^x \ln \tilde{y}_i) - \sum_{i=1}^N \ln \tilde{y}_i \sum_{i=1}^N \tilde{y}_i^x} \quad (1.30)$$

En pratique, cette convergence est rapide et le neuvième ou le dixième terme de la suite donne une bonne approximation de C ($C_9 \approx \hat{C}_{MV}$) (cf. paragraphe 1.3.4). Cette estimation est ensuite utilisée dans l'équation (1.33) pour obtenir $\hat{\alpha}_{MV}$. Pour une convergence rapide, on doit prendre pour premier terme de la suite (C_0) une valeur positive assez proche de C . Pour notre application, on prend $C_0 = 1$ ce qui correspond à une distribution exponentielle (cf. figure 1.1). En résumé, les estimateurs MV de la loi de Weibull sont donnés dans le tableau 1.1.

$$\widehat{\min}_{MV} \approx \hat{y}_{\min} - 1 \quad (1.31)$$

$$\hat{C}_{MV} = \lim_{n \rightarrow \infty} C_n \quad (\dagger) \quad (1.32)$$

$$\hat{\alpha}_{MV} = \left(\frac{1}{N} \sum_{i=1}^N \tilde{y}_i^{\hat{C}_{MV}} \right)^{\frac{1}{\hat{C}_{MV}}} \quad (1.33)$$

($\dagger$) avec $C_n = F(C_{n-1})$, $F(x)$ défini par la relation (1.30) et $C_0 = 1$.

TAB. 1.1 – *Estimateurs MV de la loi de Weibull.*

Étude des estimateurs On pourra vérifier en annexe que l'estimateur $\hat{\alpha}_{MV}$ possède de bonnes propriétés asymptotiques. Par contre, étant donné l'absence de forme explicite pour l'estimateur $\hat{C}_{MV}$ ($\hat{C}_{MV}$ est calculable mais non exprimable), il est difficile de vérifier si celui-ci possède de bonnes propriétés asymptotiques. Néanmoins, si un estimateur non biaisé et efficace de $\hat{C}$ existe, alors il est donné par l'estimation du MV² et est donc solution de l'équation (1.26). En toute rigueur, il n'existe pas de meilleur estimateur de $\hat{C}$ que celui donné par le critère du MV. On ne peut juger de l'efficacité de cet estimateur qu'expérimentalement (cf. paragraphe 1.3.4).

1.3.4 Résultats des estimateurs MV

Dans ce paragraphe, nous testons l'efficacité des estimateurs MV de la loi de Weibull définis dans le tableau 1.1 pour une image donnée ne comportant qu'une seule classe. Ces estimateurs sont testés sur des images SONAR réelles et synthétiques (avec des paramètres connus). Les tests permettent de juger de la qualité de l'estimation obtenue ainsi que la rapidité de convergence de la méthode utilisée pour obtenir une estimation de $\hat{C}_{MV}$ (méthode des suites récurrentes) puis de $\hat{\alpha}_{MV}$.

Images réelles

La figure 1.2 représente une image SONAR réelle d'un fond marin sablonneux. Cette image ne comporte qu'une seule classe. Le calcul des estimateurs MV (cf. tableau 1.2) permet d'obtenir une estimation des paramètres ($\min, \alpha, C$) du modèle du bruit de cette image (l'histogramme de cette image est considéré comme étant une loi de Weibull).

La méthode des suites récurrentes permet d'obtenir rapidement une bonne estimation de $\hat{C}_{MV}$. Le tableau de la figure 1.3 donne les valeurs obtenues par les premiers termes de la suite pour cette image ainsi que la représentation graphique de la fonction $F(x)$ et la fonction $y = x$. L'intersection de ces deux courbes a pour abscisse $\hat{C}_{MV}$ ($\hat{C}_{MV}$ est défini, on le rappelle, comme étant la solution unique de l'équation $F(\hat{C}_{MV}) = \hat{C}_{MV}$). Les premiers termes de cette suite sont représentés graphiquement en figure 1.3 et montrent que la convergence est rapide. Les estimateurs MV ($\hat{\Phi}_y = (\widehat{\min}_{MV}, \hat{\alpha}_{MV}, \hat{C}_{MV})$) estimés sur l'image "sand" sont regroupés dans le tableau 1.2.

Estimation MV				
image sand	$\hat{\Phi}_y$	$44_{(\widehat{\min}_{MV})}$	$2.75_{(\hat{C}_{MV})}$	$95_{(\hat{\alpha}_{MV})}$

TAB. 1.2 – *Estimation MV associée à l'image "sand" (loi de Weibull).*

On ne connaît pas les vrais paramètres associés à l'histogramme de cette image (ni sa nature exacte). On

2. Le contraire n'est pas vrai : un estimateur MV n'est pas toujours sans biais et efficace.





FIG. 1.2 – Image SONAR réelle “sand” de fond sablonneux (a) et histogramme associé (b).

C_n	estimé
C_0	1.000
C_1	5.962
C_2	1.792
C_3	3.724
C_4	2.280
C_5	3.124
C_6	2.534
C_7	2.904
C_8	2.654
C_9	2.816
C_{10}	2.708
C_{11}	2.778
C_{12}	2.732
C_{13}	2.762
C_{14}	2.742
C_{15}	2.755

FIG. 1.3 – Convergence de la suite C_n pour l’estimation de $\hat{C}_{MV}$ ($\hat{C}_{MV} = \lim_{n \rightarrow \infty} C_n$) sur l’image “sand”.

peut néanmoins constater graphiquement que la loi de Weibull construite à partir des paramètres estimés au sens du MV est très proche de cet histogramme. La valeur de $\hat{C}_{MV}$ (facteur de forme de la loi de Weibull), proche de 2, montre qu’une loi de Rayleigh n’est pas une très bonne approximation du modèle du bruit associé à cette image. Nous avons représenté en figure 1.4 l’histogramme de l’image “sand” ainsi que la loi de Weibull construite sur la base des paramètres estimés. Nous avons représenté aussi la loi de Rayleigh construite à partir des estimateurs MV définis au paragraphe 1.3.2. On peut remarquer visuellement que la modélisation par une loi de Weibull est plus juste et plus proche de la physique du phénomène observé.




FIG. 1.4 – Histogramme de l'image “sand” et modélisation par une loi de Rayleigh et une loi de Weibull.

Images synthétiques

Nous avons recréé synthétiquement du bruit blanc de Rayleigh de paramètre $\alpha^2 = 2500$ équivalent à un bruit de Weibull de paramètre $C = 2$ et $\alpha = 70.7$.³ La figure 1.5 représente ce bruit synthétique ainsi que l'histogramme qui lui est associé.




FIG. 1.5 – Image synthétique “sandsynth” de fond sablonneux (a) et histogramme associé (b).

La méthode des suites récurrentes permet d'obtenir une bonne estimation de $\hat{C}_{MV}$. La valeur estimée est proche de la valeur spécifiée (estimation avec moins de un pour cent d'erreur). Nous avons indiqué en figure 1.6 les valeurs obtenues par les premiers termes de la suite récurrente $C_n = F(C_{n-1})$. Les valeurs spécifiées du bruit créé et les paramètres estimés sont ensuite regroupés dans le tableau 1.3.

C_n	estimé
C_0	1.000
C_1	3.335
C_2	1.500
C_3	2.478
C_4	1.784
C_5	2.201
C_6	1.920
C_7	2.096
C_8	1.981
C_9	2.054
C_{10}	2.006
C_{11}	2.037
C_{12}	2.017
C_{13}	2.030
C_{14}	2.022




FIG. 1.6 – Convergence de la suite C_n pour l'estimation de $\hat{C}_{MV}$ sur l'image “sandsynth”.

3. On a la relation d'équivalence suivante: $\mathcal{W}(y; \min, C = 2, \alpha^2) = \mathcal{R}(y; \min, \frac{\alpha^2}{2})$

Estimation MV				
Image <i>sandsynth</i>	Φ_y	49 _(min)	2.00 _(C)	70.7 _(\alpha)
	$\hat{\Phi}_y$	49 _(\hat{min}_{MV})	2.03 _(\hat{C}_{MV})	71.4 _(\hat{\alpha}_{MV})

TAB. 1.3 – Paramètres réels et estimations MV associées à l'image “sandsynth”.

1.4 Estimateur des données incomplètes

Nous avons supposé jusqu’ici qu’il existait une seule et unique classe dans l’image SONAR (X dans ce cas était connu ou *observable*) et calculé les estimateurs MV des paramètres du modèle du bruit de cette image (à partir des *données complètes* $Z = (X, Y)$). Le problème d’estimation que nous devons résoudre est plus complexe. Il existe deux classes dans une image SONAR (classe *ombre* et classe *réverbération*)⁴ et les bruits associés à chacune de ces deux classes sont différents. De plus, on ne connaît pas la classe (ou l’étiquette) associée à chaque pixel de cette image (X dans ce cas est non *observable* et on ne dispose que des *données incomplètes* Y). Le problème d’estimation que nous devons résoudre consiste à estimer les paramètres de la loi de répartition des niveaux de gris (associés à chacune des deux classes de l’image SONAR) d’après la distribution des intensités observées.

1.5 Algorithmes locaux

Soit l’échantillon $y = (y_1, y_2, \dots, y_N)$, réalisation particulière de Y dont la loi est cette fois-ci :

$$P_Y(y) = \sum_{p=0}^1 \pi_p P_{Y_i/X_i}(y_i/e_p) \quad (1.34)$$

en notant π_p , la probabilité qu’un point de l’échantillon y suive la loi $P_{Y_i/X_i}(y_i/e_p)$. Connaissant y et $P_Y(y)$, le problème consiste à estimer les paramètres Φ_y d’un mélange de densités de probabilité et plus précisément d’estimer les paramètres des lois $P_{Y_i/X_i}(y_i/e_0)$ et $P_{Y_i/X_i}(y_i/e_1)$ et les proportions π_0 et π_1 .

Les algorithmes proposés et décrits dans ce paragraphe sont les plus simples. Ils supposent les v.a. X_i indépendantes entre elles. Ces méthodes d’estimation ne prennent donc pas en compte le caractère markovien du champ d’étiquettes.

1.5.1 Algorithme EM

Dans ce qui suit, nous présentons l’algorithme EM (*Expectation Maximization*) et son utilisation pour l’estimation des paramètres d’un mélange de densités de probabilité [14, 29]. L’algorithme EM est un algorithme itératif qui peut être utilisé pour calculer ces paramètres au sens du MV quand les observations sont vues comme étant des *données incomplètes*. Chaque itération de l’algorithme consiste en une étape de calcul d’espérance suivi d’une étape de maximisation. L’idée de l’algorithme EM est d’utiliser, non pas la densité de probabilité des données incomplètes comme cela est utilisé lors d’une estimation au sens du maximum de vraisemblance ($\hat{\Phi}_{MV} = \arg \max_{\Phi} \ln P_{Y/X, \Phi}(y/x, \Phi)$ et dans ce cas X est observable) mais la densité de probabilité des données complètes : $P_{Z/\Phi}(z/\Phi)$, avec $Z = (X, Y)$. Les deux étapes de cet algorithme sont les suivantes (p en indice désigne la $p^{\text{ième}}$ itération) :

4. on rappelle que dans le premier modèle de bruit que nous testerons, la répartition des niveaux de gris situés dans une zone d’ombre est modélisée par une loi normale, et celle associée au bruit de speckle (ou aux zones de réverbération), par une loi de Rayleigh décalée. Dans le deuxième modèle de bruit, la répartition des niveaux de gris associés à chacune de ces deux classes est modélisée par une loi de Weibull.

• **Étape E** (*Espérance*)

on calcule la fonction $Q(\Phi, \hat{\Phi}^{[p]})$

$$Q(\Phi, \hat{\Phi}^{[p]}) \triangleq E[\ln P_{Z/\Phi}(z/\Phi) \mid y, \hat{\Phi}^{[p]}] \quad (1.35)$$

• **Étape M** (*Maximisation*)

on détermine $\hat{\Phi}^{[p+1]}$ qui maximise $Q(\Phi, \hat{\Phi}^{[p]})$

$$\hat{\Phi}^{[p+1]} = \arg \max_{\Phi} Q(\Phi, \hat{\Phi}^{[p]}) \quad (1.36)$$

On peut interpréter cet algorithme de la façon suivante : ne connaissant pas la fonction de vraisemblance des données complètes, on la remplace par l'espérance conditionnellement aux observations, y , et des paramètres estimés disponibles à l'étape courante. On peut montrer qu'en combinant ces deux étapes, la fonction de log-vraisemblance, notée $\ln \mathcal{L}(\Phi) = \ln P_{Y/\Phi}(y/\Phi) = \ln \sum_x P_{X,Y/\Phi}(x, y/\Phi)$, croît [29].

Caractéristique de cette approche

- L'algorithme EM fournit en général de bons résultats si le nombre de valeurs de l'espace des états des X_i est connue.
- Il converge extrêmement lentement et n'est pas assuré de converger vers un bon maximum.

Considérons le cas le plus simple, les v.a. Y_i sont supposées indépendantes conditionnellement aux X_i et les X_i indépendantes entre elles ($i = 1, 2, \dots, N$). Dans ce cas, nous pouvons écrire :

$$\ln P_{Z/\Phi}(z/\Phi) = \ln P_{X,Y/\Phi}(x, y/\Phi) \quad (1.37)$$

$$= \ln P_{Y/X, \Phi_y}(y/x, \Phi_y) + \ln P_{X/\Phi_x}(x/\Phi_x) \quad (1.38)$$

$$= \sum_{i=1}^N \ln P_{Y_i/X_i, \Phi_y}(y_i/x_i, \Phi_y) + \sum_{i=1}^N \ln P_{X_i/\Phi_x}(x_i/\Phi_x) \quad (1.39)$$

Considérons maintenant un vecteur $\mathbf{x}_i$ à K dimensions (correspondant aux K classes recherchées, $K = 2$ dans notre application) dont les composantes sont toutes initialisées à zéro exceptée pour la $k^{\text{ème}}$ composante associée à l'étiquette de y_i $\mathbf{x}_{i,k} = \delta(k, x_i)$. Nous avons :

$$\ln P_{Y_i/X_i, \Phi_y}(y_i/x_i, \Phi_y) = \mathbf{x}_i^t U(y_i/\Phi_y) \quad (1.40)$$

$$\text{avec } U(y_i/\Phi_y) = (\ln P_{Y_i/X_i, \Phi_y}(y_i/e_0, \Phi_y), \dots, \ln P_{Y_i/X_i, \Phi_y}(y_i/e_{K-1}, \Phi_y))^t \quad (1.41)$$

Et de façon similaire :

$$\ln P_{X_i/\Phi_x}(x_i/\Phi_x) = \mathbf{x}_i^t V(\Phi_x) \quad (1.42)$$

$$\text{avec } V(\Phi_x) = \left(\underbrace{\ln P_{X_i/\Phi_x}(e_0/\Phi_x)}_{\ln \pi_0}, \dots, \underbrace{\ln P_{X_i/\Phi_x}(e_{K-1}/\Phi_x)}_{\ln \pi_{K-1}} \right)^t \quad (1.43)$$

Les relations (1.35), (1.37), (1.40), (1.42) permettent d'écrire l'expression $Q(\Phi, \hat{\Phi}^{[p]})$ sous la forme :

$$Q(\Phi, \hat{\Phi}^{[p]}) = \sum_{i=1}^N E[\mathbf{x}_i^t | y, \hat{\Phi}^{[p]}] U(y_i / \Phi_y) + \sum_{i=1}^N E[\mathbf{x}_i^t | y, \hat{\Phi}^{[p]}] V(\Phi_x) \quad (1.44)$$

où les estimations conditionnelles des composantes sont données par :

$$E[\mathbf{x}_{ik} | y] = P_{X_i/Y}(e_k / y) \quad (1.45)$$

$$= \frac{P_{Y/X_i}(y/e_k) P_{X_i}(e_k)}{\sum_{j=0}^{K-1} (P_{Y/X_i}(y/e_j) P_{X_i}(e_j))} \quad (1.46)$$

où $\mathbf{x}_{ik}$ est la $k^{\text{ième}}$ composante de $\mathbf{x}_i$ et nous avons omis le conditionnement à $\hat{\Phi}^{[p]}$ pour alléger les notations. Si les x_i sont indépendantes des y_j pour $j \neq i$, ce qui est le cas ici, la précédente expression peut être simplifiée :

$$E[\mathbf{x}_{ik} | y] = \frac{P_{Y_i/X_i}(y_i/e_k) P_{X_i}(e_k)}{\sum_{j=0}^{K-1} (P_{Y_i/X_i}(y_i/e_j) P_{X_i}(e_j))} \quad (1.47)$$

En notant $\pi_k^{[p]} = P_{X_i}(e_k / \Phi^{[p]})$ à la $p^{\text{ième}}$ itération, nous avons :

$$\hat{\mathbf{x}}_{ik}^{[p]} = E[\mathbf{x}_{ik} | y] = \frac{\pi_k^{[p]} P_{Y_i/X_i}(y_i/e_k)}{\sum_{j=0}^{K-1} \pi_j^{[p]} P_{Y_i/X_i}(y_i/e_j)} \quad (1.48)$$

Notons que la minimisation de $Q(\Phi, \hat{\Phi}^{[p]})$ par rapport aux π_k (sous contrainte $\sum \pi_k = 1$) fournit, quel que soit le modèle de données, $\hat{\pi}_k^{[p+1]} = \sum_i \hat{\mathbf{x}}_{ik}^{[p]} / N$

Cas du mélange gaussien

$P_{Y_i/X_i}(y_i/e_k)$ est ici une loi normale de moyenne μ_k et de variance σ_k^2 . La dérivée partielle de $Q(\Phi, \hat{\Phi}^{[p]})$ s'annule pour ces deux paramètres, ce qui permet d'écrire puisque $V^t(\Phi_x)$ ne dépend ni de μ_k ni de σ_k^2 :

$$\sum_{i=1}^N [\nabla_{\Phi_y} U^t(y_i / \Phi_y)] E[\mathbf{x}_i | y, \hat{\Phi}^{[p]}] = 0 \quad (1.49)$$

Les formules de remises à jour correspondantes sont données dans le tableau 1.4.

Cas du mélange de lois de Rayleigh

On suppose dans ce cas que $P_{Y_i/X_i}(y_i/e_k) = \mathcal{R}(y; \min, \alpha^2)$ (loi de Rayleigh décalée) avec les paramètres $\Phi_y = (\min, \alpha^2)$, on cherche Φ_y qui maximise la fonction Q :

$$\hat{\Phi}_y^{[p+1]} = \arg \max_{\Phi_y} Q(\Phi, \hat{\Phi}^{[p]}) \quad (1.54)$$

En prenant la dérivée de Q , cette expression peut s'écrire :

$$\nabla_{\Phi_y} Q(\Phi, \hat{\Phi}^{[p]}) = 0 \quad (1.55)$$

$$\hat{\mu}_k^{[p+1]} = \frac{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} y_i}{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]}} \quad (1.50)$$

$$(\hat{\sigma}_k^{[p+1]})^2 = \frac{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} (y_i - \hat{\mu}_k^{[p+1]})^2}{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]}} \quad (1.51)$$

$$\text{avec} \quad \hat{\mathbf{x}}_{ik}^{[p]} = \frac{\hat{\pi}_k^{[p]} P_{Y_i/X_i, \Phi_y}(y_i/e_k, \hat{\Phi}_y^{[p]})}{\sum_{j=1}^k \hat{\pi}_j^{[p]} P_{Y_i/X_i, \Phi_y}(y_i/e_k, \hat{\Phi}_y^{[p]})} \quad (1.52)$$

$$\hat{\pi}_k^{[p+1]} = \frac{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]}}{N} \quad (1.53)$$

TAB. 1.4 – *Algorithme EM. Formule de ré-estimation dans le cas d'un mélange de deux lois Gaussiennes.*

En utilisant l'expression définie pour $Q(\Phi, \hat{\Phi}^{[p]})$ ainsi que les équations (1.44) (1.55) nous obtenons :

$$\sum_{i=1}^N [\nabla_{\Phi_y} U^t(y_i/\Phi_y)] E[\mathbf{x}_i | y, \hat{\Phi}^{[p]}] = 0 \quad (1.56)$$

ou encore puisque $\Phi_y = (\min, \alpha^2)$:

$$\sum_{i=1}^N \mathbf{x}_{ik}^{[p]} \frac{\partial}{\partial \alpha_k^2} (\ln P_{Y_i/X_i}(y_i/e_k)) = 0 \quad (1.57)$$

$$\sum_{i=1}^N \mathbf{x}_{ik}^{[p]} \frac{\partial}{\partial \min_k} (\ln P_{Y_i/X_i}(y_i/e_k)) = 0 \quad (1.58)$$

L'expression (1.57) permet de trouver $(\hat{\alpha}_k^{[p+1]})^2$ (cf. table 1.5).

$$(\hat{\alpha}_k^{[p+1]})^2 = \frac{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} (y_i - \widehat{\min}_k^{[p+1]})^2}{2 \sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]}} \quad (1.59)$$

$$\text{avec (exp. (29))} \quad \hat{\mathbf{x}}_{ik}^{[p]} = \frac{\hat{\pi}_k^{[p]} P_{Y_i/X_i, \Phi_y}(y_i/e_k, \hat{\Phi}_y^{[p]})}{\sum_{j=1}^k \hat{\pi}_j^{[p]} P_{Y_i/X_i, \Phi_y}(y_i/e_k, \hat{\Phi}_y^{[p]})} \quad (1.60)$$

$$\hat{\pi}_k^{[p+1]} = \frac{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]}}{N} \quad (1.61)$$

TAB. 1.5 – *Algorithme EM. Formule de ré-estimation dans le cas d'un mélange de 2 lois de Rayleigh.*

Il est par contre difficile de trouver $\widehat{\min}_k^{[p+1]}$, l'expression (1.58) se simplifie :

$$\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} \frac{1}{(y_i - \widehat{\min}_k^{[p+1]})^2} - \frac{1}{(\alpha_k^{[p+1]})^2} (y_i - \widehat{\min}_k^{[p+1]})^2 = 0 \quad (1.62)$$

L'estimation de $\widehat{\min}$ reste donc délicate par l'algorithme EM et nous devons utiliser une autre méthode pour estimer ce paramètre (cf. paragraphe 1.7).

Cas du mélange de lois de Weibull

Dans ce cas $P_{Y_i/X_i}(y_i/e_k)$ est une loi de Weibull et $\Phi_y^{[p]} = (\widehat{min}_k^{[p]}, \hat{\alpha}_k^{[p]}, \hat{C}_k^{[p]})$ (paramètres associés à la $k^{ième}$ classe et obtenus à la $p^{ième}$ itération de l'algorithme) est solution du système :

$$\left\{ \begin{array}{l} \sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} \frac{\partial}{\partial min_k} \left(\ln P_{Y_i/X_i}(y_i/e_k) \right) = 0 \\ \sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} \frac{\partial}{\partial \alpha_k^{[p]}} \left(\ln P_{Y_i/X_i}(y_i/e_k) \right) = 0 \\ \sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} \frac{\partial}{\partial C_k} \left(\ln P_{Y_i/X_i}(y_i/e_k) \right) = 0 \end{array} \right. \quad (1.63)$$

Le calcul permet facilement de trouver les formules de ré-estimation du paramètre α associé à la $k^{ième}$ classe et obtenu à la $p^{ième}$ itération de l'algorithme (i.e., $\hat{\alpha}_k^{[p]}$) :

$$\hat{\alpha}_k^{[p]} = \left(\frac{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]} \cdot \tilde{y}_i^{[p]C}}{\sum_{i=1}^N \hat{\mathbf{x}}_{ik}^{[p]}} \right)^{\frac{1}{C}} \quad (1.64)$$

Par contre $\widehat{min}_k$ n'est pas estimable par cette méthode et le calcul de $\hat{C}$ n'est pas possible. L'algorithme EM ne peut donc pas être utilisé pour estimer un mélange de lois de Weibull. Ce résultat était prévisible car l'estimateur $\hat{C}_{MV}$, défini comme étant la valeur qui maximise la fonction de vraisemblance des *données incomplètes* ($\hat{C}_{MV} = \arg \max_C \ln P_{Y/C}(y/C)$ et avec X observable) n'était déjà pas exprimable. Le calcul de l'estimateur $\hat{C}$ défini par l'algorithme EM comme étant la valeur qui maximise la fonction de vraisemblance des *données complètes* ($\hat{C}^{[p]} = \arg \max_C E[\ln P_{X,Y/C}(x, y/C) | y, C]$) ne pouvait être qu'inextricable. Dans le cas présent, ce calcul est aussi impossible.

Cas du mélange de lois différentes

Les formules de ré-estimation dans le cas d'un mélange de lois Gaussiennes et de lois de Rayleigh existent (cf. table 1.4 et 1.5). La modification de l'algorithme EM pour l'estimation des paramètres d'un mélange de lois différentes (modèle de bruit Gauss-Rayleigh) reste possible et est résumée dans le tableau 1.6.

1.5.2 Algorithme SEM

L'algorithme SEM (*Stochastique, Estimation, Maximisation*) a pour but de déterminer les composantes d'un mélange fini de lois de probabilité, ainsi que le nombre lui-même de ces composantes par une approche d'apprentissage probabiliste. Variante stochastique de l'algorithme EM (d'où son nom S.EM), l'algorithme SEM répond en grande partie aux limitations de l'algorithme EM. En particulier, il est suffisant de connaître un majorant du nombre de classes et son principe (tirage de configurations aléatoires) le rend beaucoup moins sensible à l'initialisation que l'algorithme EM. Les différentes étapes de cet algorithme sont les suivantes :

Au départ, on fixe le paramètre K , majorant supposé du nombre de composantes du mélange, et un seuil $\delta \in]0, 1[$.

□ **Algorithme** EM (POUR L'ESTIMATION D'UN MÉLANGE DE 2 LOIS DIFFÉRENTES).

$\hat{\Phi}_y^{[0]} = (\hat{\Phi}_{y,\mathcal{G}}^{[0]}, \hat{\Phi}_{y,\mathcal{R}}^{[0]})$	vecteur de paramètres initial
$\hat{\Phi}_{y,\mathcal{G}}$	vecteur de paramètres associé à la loi Gaussienne
$\hat{\Phi}_{y,\mathcal{R}}$	vecteur de paramètres associé à la loi de Rayleigh

- Calcul de $\hat{\Phi}_y^{[p+1]}$ à partir de $\hat{\Phi}_y^{[p]}$
 - Étape de calcul d'*Espérance*
Pour chaque y_i , on calcule, en se basant sur les paramètres calculés à l'itération précédente, les probabilités $\hat{\mathbf{x}}_{ik=\text{ombre}}^{[p]}$ et $\hat{\mathbf{x}}_{ik=\text{réverbération}}^{[p]}$ (cf. tableau 1.4 ou 1.5) avec :

$$P_{Y_i/X_i, \Phi_y}(y_i/e_0 = \text{ombre}, \hat{\Phi}_y^{[p]}) \sim \mathcal{N}(y_i; \Phi_{y,\mathcal{G}}^{[p]})$$

$$P_{Y_i/X_i, \Phi_y}(y_i/e_1 = \text{réverbération}, \hat{\Phi}_y^{[p]}) \sim \mathcal{R}(y_i; \Phi_{y,\mathcal{R}}^{[p]})$$

- Étape de *Maximisation*
 - ▷ Pour $\hat{\Phi}_{y,\mathcal{G}}^{[p+1]}$, on ré-estime la moyenne, la variance et la proportion en utilisant les relations données dans le tableau 1.4
 - ▷ Pour $\hat{\Phi}_{y,\mathcal{R}}^{[p+1]}$, on ré-estime le paramètre α^2 et la proportion de cette classe par les relations données dans le tableau 1.5.

Retour à l'étape d'estimation jusqu'à la réalisation d'un critère d'arrêt.

Généralement :

si $\hat{\Phi}_y^{[p+1]} \not\approx \hat{\Phi}_y^{[p]}$ $p \leftarrow (p + 1)$ et retour à l'étape d'estimation.

TAB. 1.6 – *Algorithme EM pour l'estimation des paramètres d'un mélange de deux lois différentes (loi gaussienne pour la répartition des pixels dans une zone d'ombre et loi de Rayleigh pour la répartition des pixels dans une zone de réverbération).*

Initialisation Pour chaque observation y_i , on calcule la probabilité initiale d'appartenance $P_{X_i/Y_i}(e_m/y_i)$ à l'une des classes e_m ($0 \leq m < K$). En l'absence d'information, on prend pour $P_{X_i/Y_i}(e_m/y_i)$, la distribution uniforme. L'exposant désigne ici l'itération. Pour tout $p \geq 0$:

• **Étape S** *Stochastique*

Pour chaque y_i , on sélectionne x_i parmi l'une des classes $\{e_0, \dots, e_{K-1}\}$ selon les probabilités d'appartenance $(P_{X_i/Y_i}(e_0/y_i, \hat{\Phi}^{[p]}), \dots, P_{X_i/Y_i}(e_{K-1}/y_i, \hat{\Phi}^{[p]}))$. Ces réalisations définissent une partition $x^{[p]}$ de l'échantillon $y = \{y_1, y_2, \dots, y_N\}$.

• **Étape M** *Maximisation*

L'idée de l'algorithme SEM est de supposer que chaque y_i tel que $x_i^{[p]} = m$ est réalisé selon la distribution définie par $P_{Y/X_i}(y/e_m)$, la densité de probabilité (DDP) correspondante à la classe e_m . Nous pouvons estimer les différents paramètres du mélange de distributions selon le critère du MV sur les données complètes. Ce qui donne $\hat{\Phi}_y^{[p+1]}$ et $\hat{\pi}_m^{[p+1]} = |\{i : x_i^{[p]} = m\}|/N$ (fréquence empirique). Si pour un certain m , $\hat{\pi}_m$ (la proportion de la classe m) est inférieure à un certain seuil δ , on élimine la classe correspondante et l'algorithme continue sur la base de $(K - 1)$ composantes.

• **Étape E** *Estimation*

Pour chaque y_i , on définit la distribution suivante $(P_{X_i/Y_i}(e_0/y_i, \hat{\Phi}^{[p+1]}), \dots, P_{X_i/Y_i}(e_{K-1}/y_i, \hat{\Phi}^{[p+1]}))$ en se basant sur les paramètres calculés à l'itération $(p + 1)$:

$$P_{X_i/Y_i}(e_m/y_i, \hat{\Phi}^{[p+1]}) = \frac{\pi_m^{[p+1]} P_{Y_i/X_i}(y_i/e_m, \hat{\Phi}^{[p+1]})}{\sum_{j=0}^{K-1} \pi_j^{[p+1]} P_{Y_i/X_i}(y_i/e_j, \hat{\Phi}^{[p+1]})} \quad (1.65)$$

Retour ensuite à l'étape S.

Caractéristique de cette approche

- De nombreuses simulations ont montré le bon comportement asymptotique de cet algorithme [17].
- Son étude théorique a été réalisée dans le cas d'un mélange de distributions gaussiennes.
- A la stabilité de l'algorithme, on obtient non pas une seule partition mais une classe de partitions statistiquement admissibles pour les estimations des paramètres du mélange. Ces estimations sont précises et asymptotiquement sans biais [17].
- On ne dispose pas actuellement de procédure statistique pour déterminer le nombre minimum d'itérations à partir duquel on peut considérer que la suite des paramètres acquiert son comportement stationnaire [17]. On doit faire fonctionner l'algorithme suffisamment longtemps pour être assuré d'avoir atteint l'état stationnaire (phase d'apprentissage).

Pour notre application, l'estimation des paramètres d'un mélange de deux lois différentes ou de deux lois de Weibull, la méthode SEM est directement applicable et est résumée dans le tableau 1.7.

1.6 Algorithme global

Ces algorithmes, plus élaborés, ont la propriété et l'avantage sur les algorithmes locaux de prendre en compte le caractère markovien du champ d'étiquettes x . Les informations *a priori* que l'on a sur x (et qui se traduisent

□ **Algorithme SEM**

$\hat{\Phi}_y^{[0]}$ vecteur de paramètres initial
 $\pi^{[0]}$ proportions initiales

- Calcul de $\hat{\Phi}_y^{[p+1]}$ à partir de $\hat{\Phi}_y^{[p]}$
 - Étape E
Pour chaque y_i , on définit ensuite $(P_{X_i/Y_i}(e_0/y_i), P_{X_i/Y_i}(e_1/y_i))$ en se basant sur $\hat{\Phi}_y^{[p]}$ (expression (1.65)).
 - Étape S
Pour chaque y_i , on sélectionne x_i parmi l'une des classes (e_0, e_1) selon les probabilités d'appartenance $(P_{X_i/Y_i}(e_0/y_i, \hat{\Phi}_y^{[p]}), P_{X_i/Y_i}(e_1/y_i, \hat{\Phi}_y^{[p]}))$. Ces réalisations définissent un étiquetage $x^{[p]}$ de $y = \{y_1, y_2, \dots, y_N\}$.
 - Étape M
On utilise les estimateurs MV sur cette image partitionnée pour obtenir $\hat{\Phi}_y^{[p+1]}$, et $\hat{\pi}_m^{[p+1]}$ (fréquence d'apparition de e_m dans $x^{[p]}$).

Retour à l'étape E jusqu'à la réalisation d'un critère d'arrêt.

Généralement :

si $\hat{\Phi}_y^{[p+1]} \not\approx \hat{\Phi}_y^{[p]}$ $p \leftarrow (p + 1)$ retour à l'étape E.

TAB. 1.7 – *Algorithme SEM pour l'estimation des paramètres d'un mélange de distributions (mélange de lois différentes ou mélange de lois de Weibull).*

par les valeurs données aux différents potentiels associés à chaque clique) sont ici utilisées pour l'estimation des paramètres du modèle du bruit.

1.6.1 Algorithme ECI

Contexte général

Soit Φ_y les paramètres du modèle de données, dont dépend la loi conjointe $P_{X,Y}(x, y)$ et $\hat{\Phi}_y$ l'estimation de Φ_y à partir de (X, Y) . L'idée de l'ECI [86] est de considérer un tel estimateur $\hat{\Phi}_y(X, Y)$ et de rechercher son approximation dans l'ensemble des variables aléatoires, fonctions de y , la seule observation. La meilleure approximation, au sens de l'erreur quadratique moyenne est l'espérance conditionnelle. Comme cette espérance conditionnelle dépend de Φ_y , qui est par nature inconnue, l'approche itérative suivante a été proposée : $\hat{\Phi}_y^{[p+1]} = E_p[\hat{\Phi}_y(X, Y)|Y = y]$ (E_p est l'espérance conditionnelle correspondante relative au paramètre $\hat{\Phi}_y^{[p]}$). Finalement la démarche de la procédure ECI est la suivante :

- On considère une valeur initiale $\hat{\Phi}_y^{[0]}$.
- $\hat{\Phi}_y^{[p+1]}$ est calculé à partir de $\hat{\Phi}_y^{[p]}$ et $Y = y$ par la relation :

$$\hat{\Phi}_y^{[p+1]} = E_p[\hat{\Phi}_y(X, Y)|Y = y] \quad (1.66)$$

$$= \sum_x \hat{\Phi}_y(x, y) P(x/y, \hat{\Phi}_y^{[p]}) \quad (1.67)$$

L'ECI n'admet pas actuellement de justification mathématique complète, cependant son principe reste assez intuitif et s'appuie sur la propriété fondamentale de l'espérance conditionnelle énoncée plus haut. Lorsque l'estimateur $\hat{\Phi}_y(X, Y)$ possède de bonnes propriétés asymptotiques, $E_p[\hat{\Phi}_y(X, Y)|Y = y]$ permet une bonne estimation de Φ_y [86].

Lorsque $E_p[\hat{\Phi}_y(X, Y)|Y = y]$ n'est pas explicitement calculable mais la simulation des réalisations de X selon la loi conditionnelle à Y possible, on peut utiliser une approximation stochastique de type Monte Carlo. En effet, l'espérance conditionnelle est aussi l'espérance selon la loi conditionnelle et peut être approchée en vertu de la loi des grands nombres par la moyenne empirique. On peut ainsi simuler n réalisations $(x_{(1)}, \dots, x_{(n)})$ de X selon la distribution *a posteriori* $P_{X/Y, \Phi}(x/y, \hat{\Phi}_y^{[p]})$ et poser :

$$\hat{\Phi}_y^{[p+1]} \triangleq \frac{1}{n} [\hat{\Phi}_y(x_{(1)}, y) + \dots + \hat{\Phi}_y(x_{(n)}, y)] \quad (1.68)$$

En conclusion, l'utilisation de l'ECI est possible dès que :

- On dispose d'une valeur initiale $\hat{\Phi}_y^{[0]}$ assez proche de Φ_y .
- On dispose d'un estimateur $\hat{\Phi}_y(X, Y)$ de Φ_y à partir des données complètes.
- On dispose d'une méthode de simulation, valable pour tout Φ_y , des réalisations de X selon la loi conditionnelle à $Y = y$.

En supposant, conformément au principe général de l'ECI, que x est observable, nous avons montré précédemment que l'on disposait d'estimateurs des *données complètes* $\hat{\Phi}_y(X, Y)$ au sens du MV pour nos deux types de modèle de bruit. Nous avons montré, de plus, que ces estimateurs possédaient de bonnes propriétés asymptotiques. Dans notre application, le calcul de $E_p[\hat{\Phi}_y(X, Y)|Y = y]$ pour les paramètres Φ_y n'est pas calculable explicitement et on doit procéder à son approximation en utilisant l'expression (1.68). La simulation de n réalisations $(x_{(1)}, \dots, x_{(n)})$ de X selon sa loi conditionnelle à Y est possible au moyen de procédures itératives de type échantillonneur de Gibbs [36].

Caractéristique de cette approche

- Basée sur la notion d'espérance mathématique conditionnelle plutôt que sur celle de vraisemblance, cette approche paraît d'application plus large car elle permet de traiter le cas des lois de probabilité comportant une partie continue et une partie discrète pour lesquelles l'estimateur du MV perd son sens [28].
- De plus, l'utilisation de l'ECI n'est pas limitée par la forme des lois de probabilité associées au bruit. En particulier, ces lois peuvent être de nature différente [13].

Pour notre application, l'estimation des paramètres d'un mélange de deux lois différentes ou de deux lois de Weibull, la procédure ECI peut être utilisée et est résumée dans le tableau 1.8.

□ Algorithme ECI $\hat{\Phi}_y^{[0]}$ vecteur de paramètres initial • Calcul de $\hat{\Phi}_y^{[p+1]}$ à partir de $\hat{\Phi}_y^{[p]}$ ◦ Simulation de n réalisations $(x_{(1)}, \dots, x_{(n)})$ de X selon la distribution <i>a posteriori</i> $P_{X/Y, \Phi_y}(x/y, \hat{\Phi}_y^{[p]})$ grâce à l'échantillonneur de Gibbs et sur la base de $\hat{\Phi}_y^{[p]}$. ◦ On utilise les estimateurs MV des données complètes sur ces différentes images segmentées $x_{(i)}$ et on calcule $\hat{\Phi}_y^{[p+1]}$ par la relation : $\hat{\Phi}_y^{[p+1]} = \frac{1}{n} [\hat{\Phi}_y(x_{(1)}, y) + \dots + \hat{\Phi}_y(x_{(n)}, y)]$ On recommence jusqu'à la réalisation d'un critère d'arrêt. Généralement : si $\hat{\Phi}_y^{[p+1]} \not\approx \hat{\Phi}_y^{[p]} \quad p \leftarrow (p + 1)$

TAB. 1.8 – *Algorithme ECI pour l'estimation des paramètres d'un mélange de distributions.*

1.7 Algorithmes des K moyennes

Les algorithmes d'estimations itératifs que nous avons présentés (EM, SEM, ECI) doivent être initialisés. Cette initialisation est déterminante pour l'algorithme EM et reste d'une grande importance pour la bonne convergence des algorithmes SEM ou ECI. Ces derniers convergent d'autant plus vite que l'initialisation des paramètres du modèle de bruit est proche des valeurs recherchées. Dans notre application, cette initialisation se fait de la manière suivante. L'image SONAR est découpée en M imagerie sur lesquelles on calcule trois attributs statistiques, la moyenne des niveaux de gris contenus dans cette imagerie, la variance et l'intensité de niveau de gris minimale. Chaque imagerie est ainsi caractérisée par un vecteur à trois composantes (appelé "échantillon" ou $\mathbf{x}$ par la suite). Ces échantillons sont ensuite rassemblés en $K = 2$ groupements par l'algorithme des K moyennes en fonction d'un critère de "ressemblance" ce qui induit une partition grossière de l'image en deux classes. On utilise ensuite les estimateurs MV sur cette image partitionnée et on obtient de cette façon une première estimation des paramètres du modèle de bruit : $\hat{\Phi}_y^{[0]}$.

La répartition des différents échantillons $\mathbf{x}_l$ dans les différents groupements est effectuée de façon à minimiser un indice de dispersion. Cet indice de dispersion s'écrit :

$$J = \sum_{i=1}^K \sum_{\mathbf{x}_l \in C_i} |\mathbf{x}_l - c_i|^2 \quad (1.69)$$

où la seconde sommation se fait sur tous les échantillons $\mathbf{x}_l$ appartenant au groupement C_i dont le centre est c_i . On peut montrer facilement [4] que pour une partition $\{C_i, i = 1, \dots, K\}$ donnée, l'indice de dispersion J est minimal si le centre de chaque groupement C_i est donné par la relation suivante :

$$c_i = \frac{1}{N_i} \sum_{\mathbf{x}_l \in C_i} \mathbf{x} \quad (1.70)$$

avec N_i le nombre d'échantillons appartenant à C_i . L'algorithme des K moyennes peut se résumer dans le tableau 1.9.

□ **Algorithme K-Moy.**

1. On choisit les K premiers échantillons comme étant les K centres $(c_1^{[1]}, \dots, c_K^{[1]})$ des K groupements :

$$c_i^{[1]} = \mathbf{x}_i \quad 1 \leq i \leq K \quad (1.71)$$

2. A l'itération k , on associe l'échantillon $\mathbf{x}_l$, ($1 \leq l \leq M$) au groupement C_i (noté $C_i^{[p]}$) si :

$$\|\mathbf{x}_l - c_i^{[p]}\| < \|\mathbf{x}_l - c_j^{[p]}\| \quad \forall j \neq i \quad (1.72)$$

En fait, on associe l'échantillon $\mathbf{x}_l$ au groupement dont le centre lui est le plus proche. En cas d'égalité, on associe $\mathbf{x}_l$ arbitrairement au groupement i ou j .

3. $C_i^{[p]}$ correspond au groupement i constitué à l'itération p après l'étape 2. On détermine le nouveau centre de chaque groupement par :

$$c_i^{[p+1]} = \frac{1}{N_i} \sum_{\mathbf{x} \in C_i^{[p]}} \mathbf{x} \quad \forall i \quad (1.73)$$

avec N_i le nombre d'échantillons de $C_i^{[p]}$.

4. Si les centres des groupements à l'itération p sont les mêmes que ceux obtenus à l'itération précédente, alors les groupements constitués à l'itération p et $(p-1)$ sont identiques et l'algorithme a convergé, sinon on retourne à l'étape 2.

$$\text{si } c_i^{[p+1]} = c_i^{[p]} \quad \forall i \quad \text{fin de l'algorithme sinon on retourne en 2.} \quad (1.74)$$

TAB. 1.9 – *Algorithme des K-moyennes.*

Caractéristique de cette approche

La rapidité de convergence de la procédure dépend des échantillons arbitrairement choisis au départ. Si ces échantillons sont très éloignés, cette convergence est rapide [4].

L'estimation des paramètres d'un mélange de distributions par cette méthode de caractérisation et classification par l'algorithme des K -moyennes est résumée dans le tableau 1.10.

□ **Algorithme K-Moy.** POUR L'ESTIMATION DES PARAMÈTRES D'UN MÉLANGE DE DISTRIBUTIONS.

- L'image SONAR est découpée en M imageries caractérisées par un vecteur à 3 composantes (moyenne, variance, intensité de niveau de gris minimale). Chaque vecteur constitué nous donne un "échantillon".
- Les échantillons sont rassemblés en $K = 2$ groupements par l'algorithme des K moyennes (le résultat obtenu est une image partitionnée en deux classes).
- On utilise les estimateur MV des données complètes sur cette image partitionnée.

TAB. 1.10 – *Algorithme des K-moyennes pour l'estimation des paramètres d'un mélange de distributions.*

1.8 Méthode de segmentation courante

Précédemment nous nous sommes intéressés à des méthodes de segmentation non supervisées qui consistent à diviser le problème en deux étapes :

- La première étape où les paramètres du modèle sont estimés à partir du champ y , le seul observable.
- La seconde étape où ces paramètres sont ensuite utilisés pour la segmentation proprement dite.

Il existe une démarche assez différente qui est appelée *Segmentation Courante* (SC) et qui consiste à trouver la solution simultanée des problèmes d'estimation des paramètres et de segmentation. Cette démarche se réfère à toute méthode itérative dans laquelle la valeur suivante du paramètre $\hat{\Phi}_y^{[p+1]}$ est obtenue en appliquant une méthode d'estimation donnée à $(x^{[p]}, y)$ ou $x^{[p]} = S(y)$ est une segmentation de y par une stratégie S (MPM, MAP, ICM, MF, ...) utilisant la valeur courante $\hat{\Phi}_y^{[p]}$ du paramètre. Le principe est le suivant. On se donne un estimateur $\hat{\Phi}_y(X, Y)$, une stratégie de segmentation S et on pose :

$$\hat{\Phi}_y^{[p+1]} = \hat{\Phi}_y(S_{\hat{\Phi}_y^{[p]}}(y), y) \quad (1.75)$$

Notons que cette démarche ressemble à l'ECI. Les deux méthodes utilisent un estimateur $\hat{\Phi}_y(X, Y)$ et on ré-estime les paramètres en l'appliquant à des réalisations de X obtenues *artificiellement*. Lorsqu'on considère une méthode de type SC, ces réalisations sont obtenues par une segmentation et, dans le cas d'une méthode de type ECI, elles le sont par des tirages aléatoires (échantillonneur de Gibbs avec $T=1$). Notons aussi que contrairement à l'ECI, il est difficile de trouver une justification mathématique précise. De plus la stratégie de segmentation utilisée pour générer des réalisations de X est étroitement liée à une fonction de coût (coût uniforme pour le MAP, proportionnel aux sites mal classés pour le MPM etc ...) et l'estimation des paramètres obtenus, qui se fait en alternance avec la phase de segmentation, dépend donc de cette fonction de coût [86]. Pourtant l'estimation des paramètres devrait être indépendante de la stratégie de segmentation utilisée et donc de cette fonction de coût.

1.9 Relations entre les différentes méthodes d'estimation

L'objectif de ce paragraphe est de mettre en évidence les relations existant entre les différents algorithmes présentés précédemment, en particulier les algorithmes EM, SEM, ECI, et SC.

Relation ECI-EM

A première vue, les principes sur lesquels reposent les algorithmes ECI et EM sont complètement différents. Néanmoins ces algorithmes peuvent être comparés si on utilise les mêmes données complètes z et si l'estimateur choisi dans le cas de l'ECI est l'estimateur MV [28]. En effet dans le cas de la procédure ECI, la valeur suivante du paramètre $\hat{\Phi}^{[p+1]}$ est donnée à partir de sa valeur courante $\hat{\Phi}^{[p]}$ et y par :

$$\hat{\Phi}^{[p+1]} = E_p \left[\arg \max_{\Phi} \ln P_{Z/\Phi}(z/\Phi) | y, \Phi^{[p]} \right] \quad (1.76)$$

On recherche, dans ce cas, pour (x, y) , $\hat{\Phi}$ maximisant $\ln P_{Z/\Phi}(z/\Phi)$ (estimateur MV) puis on considère l'espérance conditionnelle, calculée sur la base de la valeur $\hat{\Phi}^{[p]}$ du paramètre $\hat{\Phi}(X, Y)$ ainsi obtenu. Selon l'algorithme EM, ce paramètre $\hat{\Phi}^{[p+1]}$ est lié à $\hat{\Phi}^{[p]}$ et y par :

$$\hat{\Phi}^{[p+1]} = \arg \max_{\Phi} E_p \left[\ln P_{Z/\Phi}(z/\Phi) | y, \Phi^{[p]} \right] \quad (1.77)$$

En suivant le principe de l'algorithme EM, on considère d'abord l'espérance conditionnelle, calculée sur la base de la valeur courante $\hat{\Phi}^{[p]}$, du paramètre de $\ln P_{Z/\Phi}(z/\Phi)$ puis on recherche $\hat{\Phi}$ maximisant la fonction ainsi obtenue. Ainsi dans les deux cas, on s'intéresse à $\ln P_{Z/\Phi}(z/\Phi)$ et on utilise les opérateurs [recherche du MV] et [calcul de l'espérance conditionnelle] (qui ne commutent pas dans le cas général) dans un ordre différent. Dans [28], l'auteur donne des conditions suffisantes pour lesquelles les deux opérateurs commutent, i.e., des conditions suffisantes pour que les deux algorithmes soient identiques.

Relation SEM-EM

L'algorithme SEM est présenté par les auteurs comme une variante stochastique de l'algorithme EM. La différence principale réside dans la ré-estimation des paramètres. Dans le cas de l'algorithme SEM, les ré-estimations de tous les paramètres sont faites à partir de simulations (tirages aléatoires).

Relation SEM-ECI

Les ré-estimations des paramètres sont faites pour ces deux algorithmes à partir de simulations (qui sont ensuite moyennées ensemble pour obtenir l'estimée finale). Ainsi, l'algorithme SEM peut être vu comme un algorithme ECI simplifié. Les estimations des paramètres se font sur la base d'une seule simulation et ce tirage ne prend pas en compte l'énergie contextuelle (i.e., l'information de voisinage via l'échantillonneur de Gibbs).

Relation SC-ECI

La démarche d'une segmentation courante ressemble à l'ECI. Les deux méthodes utilisent un estimateur $\hat{\Phi}_y(X, Y)$ et on ré-estime les paramètres en l'appliquant à des réalisations de x obtenues *artificiellement*. Néanmoins, lorsqu'on considère une méthode de type SC, ces réalisations sont obtenues par une segmentation et, dans le cas d'une méthode de type ECI, elles le sont par des tirages aléatoires (échantillonneur de Gibbs avec $T=1$).

1.10 Résultats expérimentaux

Dans ce paragraphe, nous présentons les résultats expérimentaux obtenus par les méthodes itératives d'estimation EM, SEM, ECI ainsi que la méthode utilisée pour initialiser ces algorithmes (méthode d'estimation basée sur l'algorithme des K -moyennes). Pour chaque algorithme, nous précisons, 1) les difficultés de mise en œuvre ainsi que les considérations pratiques associées à chacune des méthodes, 2) les résultats expérimentaux obtenus sur des images SONAR réelles ou synthétiques. Une distance de Kolmogorov ($\mathcal{K}$) et un critère du χ^2 (cf. annexe B) calculés à partir de l'histogramme de l'image (loi empirique) et des deux lois estimées du mélange (lois théoriques), permettent de juger l'efficacité de ces algorithmes et la qualité des estimations obtenues.

1.10.1 Algorithme des K -moyennes

L'algorithme est celui que nous avons décrit au paragraphe 1.7 pour l'estimation des paramètres d'un mélange de distributions.

Mise en œuvre de l'algorithme

- Les attributs calculés sur les différentes petites zones prises sur l'image initiale et qui permettent de caractériser ainsi chaque imagerie sont, pour notre application, au nombre de trois : la moyenne, la variance ainsi que l'intensité minimale des niveaux de gris contenus dans cette imagerie. Ils permettent de distinguer sans trop d'ambiguïté une zone de l'image correspondant à une zone d'ombre d'une correspondant à une zone de réverbération : les mesures de la moyenne, de la variance et de l'intensité minimale sont toujours plus faibles pour une imagerie prélevée sur une zone d'ombre.
- La taille des images est de 6×6 pixels. Les différents attributs qui permettent de caractériser chaque zone prélevée sur l'image SONAR initiale, sont donc calculés à partir d'un échantillon $\{y_1, y_2, \dots, y_{36}\}$ de 36 éléments. Cet échantillon est à la fois assez important pour permettre une bonne estimation des différents attributs (et ainsi permettre une bonne classification) et assez petit pour prendre en compte des petites zones d'ombre ou de réverbération existant dans l'image (rides de sables ou fond rocheux par exemple). Différentes tailles d'images ont été testées en [72].
- Une fois les deux groupements constitués (i.e., une fois l'image partitionnée en deux classes par l'algorithme des K -moyennes), il est simple d'identifier sans ambiguïté quel groupement (ou quelle zone de l'image) est associé à une zone d'ombre ou une zone de fond : l'intensité des pixels situés dans une zone d'ombre est en moyenne plus faible que celle des pixels situés dans une zone de fond. Dans le cas d'une estimation des paramètres d'une modélisation du bruit par deux distributions différentes (Gauss-Rayleigh), cette identification est nécessaire pour associer à chaque zone l'estimateur MV des données complètes correspondant.

Résultats expérimentaux

Les images SONAR réelles utilisées dans ce test sont présentées aux figures 1.8.a et 1.8.c. Elles représentent respectivement l'ombre portée d'une mine cylindrique et d'un rocher sur fond de sable (image “*cylindre et rocher*”) et l'ombre portée d'une mine sur un fond marin composé de cailloux et de roches (image “*cylindre sur cailloux*”). L'image SONAR synthétique utilisée est présentée à la figure 1.8.e (image “*sphère*”) et simule⁵ l'ombre portée et l'écho que pourrait créer une sphère reposant sur un fond marin de sable.

La planche 1.8 nous montre que l'algorithme des K -moyennes reconnaît facilement deux classes distinctes dans l'image SONAR ou deux groupements distincts dans l'espace des caractéristiques (cf. figure 1.7). La convergence de l'algorithme est rapide et le résultat de la classification des images (en zone d'ombre ou de réverbération) est correct. Cette première segmentation permet une bonne approximation des paramètres

5. La forme de l'ombre portée (et de l'écho) est créée par une procédure classique de “lancé de rayon”. Le bruit créé dans la zone réverbération et la partie ombre est synthétique.

du mélange de distributions et une bonne initialisation des algorithmes EM, SEM et ECI. Des résultats numériques de cette estimation du mélange de distributions sont donnés dans le paragraphe suivant.




FIG. 1.7 – Nuages de points constitués par l’algorithme des K -moyennes associés à l’image SONAR réelle présentée à la figure 1.8.a. (image “cylindre et rocher”). Chaque échantillon est représenté par un point dans l’espace des caractéristiques.

1.10.2 Algorithmes locaux : EM et SEM

Les algorithmes utilisés dans ce test sont résumés dans les tableaux 1.6 et 1.7. L’utilisation de ces deux algorithmes ne permet pas d’obtenir à chaque itération, une estimée plus précise du paramètre $\widehat{min}$, correspondant au décalage de la loi de Rayleigh ou de la loi de Weibull associé à la classe *réverbération*. Pour l’algorithme EM, $\widehat{min}$ n’est pas calculable. Quant à l’algorithme SEM, une fois ce paramètre fixé à une certaine valeur, les v.a. Y_i pour lesquelles $y_i \leq \widehat{min}$ garderont durant la phase d’estimation (étape E) une probabilité nulle d’appartenir à la classe *réverbération*. $\widehat{min}$ reste ainsi inchangé à chaque itération de l’algorithme. Lors d’une modélisation Gauss-Rayleigh ou Weibull-Weibull, ce paramètre doit être estimé et fixé une fois pour toutes par l’algorithme des K -moyennes (cf. paragraphe 1.7).

Mise en œuvre de l’algorithme

- Les deux méthodes ne posent pas de difficultés particulières de mise en œuvre particulières. Pour ces algorithmes, il n’existe pas actuellement de procédures statistiques pour déterminer le nombre minimum d’itérations à partir duquel on peut considérer que la suite des paramètres a atteint son comportement stationnaire. Pour notre application, on considère que l’algorithme a convergé lorsque la variance des N dernières estimations est en dessous d’un certain seuil. L’estimée finale est ensuite la moyenne des N dernières estimations.
- Les deux méthodes d’estimation itératives sont initialisées par le résultat d’estimation obtenu par l’algorithme des K -moyennes (cf. paragraphe 1.7).

Résultats expérimentaux

Les images SONAR réelles utilisées dans ce test sont à nouveau celles des figure 1.8.a (image “cylindre et rocher” présentée au paragraphe 1.10.1) et figure 1.8.c (image “cylindre sur cailloux”) ainsi que celle montrée à la figure 1.9.a représentant l’ombre portée d’une mine cylindrique sur fond de sable (image “cylindre sur




FIG. 1.8 – Segmentations obtenues par l'algorithme des K -moyennes sur des images SONAR réelles et synthétique. (a) (c) Images SONAR réelles (images “cylindre et rocher” et “cylindre sur cailloux”). (e) Image SONAR synthétique (image “sphère”). (b) (d) (f) Segmentations en deux classes obtenues par l'algorithme des K -moyennes.

sable). Les images SONAR synthétiques utilisées dans ce test sont données aux figures 1.8.e (image “*sphère*”) et 1.9.b. Cette dernière simule l’ombre portée et l’écho que pourrait créer un anneau métallique posé sur le fond marin (image “*anneau*”).

Les estimations obtenues par l’algorithme des K -moyennes sont regroupées dans le tableau 1.11 dans le cas d’une modélisation Gauss-Rayleigh ou Weibull-Weibull. Celles obtenues par l’algorithme EM et SEM dans le cas d’une modélisation du bruit par deux lois différentes (modèle Gauss-Rayleigh) sont placées dans le tableau 1.12 (les cases vides signifient que l’algorithme n’a pas convergé pour l’image considérée). On rappelle que l’algorithme EM ne peut être utilisé pour estimer les paramètres d’un mélange de lois de Weibull. Les expérimentations ont montré que l’algorithme SEM ne converge pas pour ce type de modèle de bruit. Rappelons que l’algorithme SEM a sa justification mathématique dans le cas d’un mélange de lois gaussiennes [17].

Les tests montrent que l’utilisation des algorithmes EM et SEM reste possible dans le cas d’une modélisation Gauss-Rayleigh seulement pour certaines images SONAR, notamment celles pour lesquelles le mélange de distributions est peu important. L’algorithme SEM semble plus performant que l’algorithme EM qui converge seulement pour deux des cinq images de ce test.

Image :		Algorithme des K -moyennes							
		Modélisation Gauss-Rayleigh				Modélisation Weibull-Weibull			
<i>cylindre sur sable</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.23 _(π)	62 _(μ)	223 _(σ^2)		0.23 _(π)	15 _($\min$)	2.6 _(C)	54 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.77 _(π)	42 _($\min$)	664 _(α^2)		0.77 _(π)	42 _($\min$)	2.4 _(C)	53 _(α)
<i>cylindre et rocher</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.17 _(π)	55 _(μ)	286 _(σ^2)		0.17 _(π)	13 _($\min$)	1.9 _(C)	50 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.83 _(π)	37 _($\min$)	952 _(α^2)		0.83 _(π)	37 _($\min$)	2.4 _(C)	73 _(α)
<i>cylindre sur cailloux</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.12 _(π)	28 _(μ)	908 _(σ^2)		0.12 _(π)	— 1 _($\min$)	1.1 _(C)	46 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.88 _(π)	15 _($\min$)	3240 _(α^2)		0.88 _(π)	15 _($\min$)	2.4 _(C)	122 _(α)
<i>sphère</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.03 _(π)	41 _(μ)	199 _(σ^2)		0.03 _(π)	11 _($\min$)	1.1 _(C)	22 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.97 _(π)	42 _($\min$)	972 _(α^2)		0.97 _(π)	42 _($\min$)	2.9 _(C)	72 _(α)
<i>anneau</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.24 _(π)	84 _(μ)	596 _(σ^2)		0.24 _(π)	11 _($\min$)	2.6 _(C)	71 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.76 _(π)	48 _($\min$)	1068 _(α^2)		0.76 _(π)	48 _($\min$)	2.5 _(C)	64 _(α)

TAB. 1.11 – Estimations obtenues par l’algorithme des K moyennes (modèle Gauss-Rayleigh et modèle Weibull-Weibull).

Image :		Modélisation Gauss-Rayleigh					
		Algorithme EM			Algorithme SEM		
cylindre sur sable	$\hat{\Phi}_{y(\text{ombre})}$	—	—	—	0.16 _(\pi)	56 _(\mu)	247 _(\sigma^2)
	$\hat{\Phi}_{y(\text{réver.})}$	—	—	—	0.84 _(\pi)	42 _(min)	892 _(\alpha^2)
		$\mathcal{K} = - \quad \chi^2 = -$			$\mathcal{K} = 0.05 \quad \chi^2 = 10000$		
cylindre et objet	$\hat{\Phi}_{y(\text{ombre})}$	—	—	—	0.25 _(\pi)	57 _(\mu)	335 _(\sigma^2)
	$\hat{\Phi}_{y(\text{réver.})}$	—	—	—	0.75 _(\pi)	37 _(min)	1442 _(\alpha^2)
		$\mathcal{K} = - \quad \chi^2 = -$			$\mathcal{K} = 0.07 \quad \chi^2 = 8800$		
cylindre sur cailloux	$\hat{\Phi}_{y(\text{ombre})}$	0.08 _(\pi)	06 _(\mu)	34 _(\sigma^2)	0.08 _(\pi)	06 _(\mu)	36 _(\sigma^2)
	$\hat{\Phi}_{y(\text{réver.})}$	0.92 _(\pi)	15 _(min)	5522 _(\alpha^2)	0.92 _(\pi)	15 _(min)	5433 _(\alpha^2)
		$\mathcal{K} = 0.16 \quad \chi^2 = 5660$			$\mathcal{K} = 0.16 \quad \chi^2 = 5725$		
sphère	$\hat{\Phi}_{y(\text{ombre})}$	0.04 _(\pi)	35 _(\mu)	48 _(\sigma^2)	0.04 _(\pi)	35 _(\mu)	50 _(\sigma^2)
	$\hat{\Phi}_{y(\text{réver.})}$	0.96 _(\pi)	42 _(min)	1335 _(\sigma^2)	0.96 _(\pi)	42 _(min)	1290 _(\alpha^2)
		$\mathcal{K} = 0.06 \quad \chi^2 = 2500$			$\mathcal{K} = 0.07 \quad \chi^2 = 2880$		
anneau	$\hat{\Phi}_{y(\text{ombre})}$	—	—	—	—	—	—
	$\hat{\Phi}_{y(\text{réver.})}$	—	—	—	—	—	—
		$\mathcal{K} = - \quad \chi^2 = -$			$\mathcal{K} = - \quad \chi^2 = -$		

TAB. 1.12 – Estimations obtenues par les algorithmes SEM et EM pour le modèle Gauss-Rayleigh.




FIG. 1.9 – Image SONAR réelle “cylindre et rocher” (a) et Image SONAR synthétique “anneau”(b).

1.10.3 Algorithme global : ECI

L'algorithme utilisé dans ce test est résumé dans le tableau 1.8. Le critère d'arrêt de l'algorithme est le même que celui des algorithmes EM et SEM.

Mise en œuvre de l'algorithme

- Une modification au modèle de bruit a été apportée dans l'algorithme ECI afin de rendre possible l'estimation du paramètre $\widehat{min}$ de la loi de Rayleigh ou Weibull associée à la classe *réverbération*. Ce modèle consiste à associer aux différentes variables aléatoires Y_i dont le niveau de gris est inférieur ou égal à min (correspondant au paramètre de décalage de la loi de Weibull ou de la loi de Rayleigh associée à la classe *réverbération*), une probabilité faible mais non nulle d'appartenir à la classe *réverbération*. Un exemple de modèle de bruit utilisé par l'échantillonneur de Gibbs est représenté à la figure 1.10.
- Pour le modèle *a priori* de l'échantillonneur de Gibbs, on utilise des potentiels d'interactions locales de la forme :

$$\beta_{st}(1 - \delta(e_s, e_t)) \quad (1.78)$$

Le système de voisinage retenu est un huit-voisinage, et seules les cliques à deux éléments sont considérées. $\beta_{st} = 1 (= \beta_1, \beta_2, \beta_3 \text{ ou } \beta_4)$ désigne le paramètre associé respectivement aux cliques horizontales, verticales, diagonales droite et diagonales gauche respectivement (cf. figure 1.11).

- Pour notre application et pour limiter le temps de calcul, nous avons choisi $n = 1$. n désigne le nombre de champs d'étiquettes simulés par l'échantillonneur de Gibbs à chaque itération de l'algorithme ECI. On peut cependant remarquer que des valeurs supérieures de n améliorent légèrement les résultats.




FIG. 1.10 – *Modélisation Weibull-Weibull modifiée.*




FIG. 1.11 – *Cliques à deux éléments pour le voisinage du 2ⁿ ordre et paramètres associés.*

Résultats expérimentaux

Les résultats montrent que l'algorithme ECI peut être utilisé efficacement en imagerie SONAR pour l'estimation des paramètres d'un mélange de lois différentes (mélange Gauss-Rayleigh) ou un mélange de lois de Weibull. L'algorithme ECI converge pour ces deux types de modélisation et pour l'ensemble des images de notre base de test (qui comprend une centaine d'images [72, 74]). Cette convergence est assurée également pour les images SONAR dont le mélange de distribution est important.

On peut remarquer (cf. tableau 1.13) qu'une modélisation Weibull-Weibull est plus juste au sens du critère du χ^2 et de la distance de Kolmogorov qu'une modélisation Gauss-Rayleigh. On peut aussi le constater visuellement (cf. figures 1.12 et 1.13) en comparant l'histogramme de l'image et le mélange de densités de probabilités estimé par la procédure ECI. Ce phénomène est particulièrement visible pour l'image “*cylindre sur cailloux*” où la loi de répartition des niveaux de gris associés à la classe *ombre* est plus proche d'une loi exponentielle que d'une loi gaussienne (ce que confirme l'estimation par l'ECI du facteur de forme $C = 1.1$).

Les valeurs estimées du facteur de forme C pour la classe *réverbération* sont relativement proches de 2 (les valeurs estimées sont comprises entre 1.8 et 2.2). Une loi de Rayleigh reste donc une assez bonne approximation du modèle de bruit associé à la classe *réverbération*. Par contre, les valeurs de $\hat{C}$ pour la classe *ombre* sont assez différentes et varient de $C = 1.1$ à $C = 3.6$.

L'algorithme ECI montre une convergence plus rapide dans le cas d'une modélisation du bruit par lois de Weibull comparativement à une modélisation Gauss-Rayleigh. En fait, chaque itération de l'algorithme nécessite plus de calculs (à cause de l'estimation itérative de C par la méthode des suites récurrentes), mais nécessite moins d'itérations pour la convergence de l'algorithme.

Image :		Algorithme ECI							
		Modélisation Gauss-Rayleigh				Modélisation Weibull-Weibull			
<i>cylindre sur sable</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.03 _(π)	31 _(μ)	22 _(σ^2)		0.06 _(π)	15 _($\min$)	3.2 _(C)	26 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.97 _(π)	37 _($\min$)	1020 _(α^2)		0.94 _(π)	42 _($\min$)	1.8 _(C)	40 _(α)
		$\mathcal{K} = 0.07 \quad \chi^2 = 142000$				$\mathcal{K} = 0.06 \quad \chi^2 = 16300$			
<i>cylindre et objet</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.03 _(π)	24 _(μ)	22 _(σ^2)		0.05 _(π)	13 _($\min$)	2.2 _(C)	21 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.97 _(π)	33 _($\min$)	1420 _(α^2)		0.95 _(π)	37 _($\min$)	1.8 _(C)	49 _(α)
		$\mathcal{K} = 0.1 \quad \chi^2 = 12500$				$\mathcal{K} = 0.08 \quad \chi^2 = 6100$			
<i>cylindre sur cailloux</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.07 _(π)	04 _(μ)	21 _(σ^2)		0.10 _(π)	— 1 _($\min$)	1.1 _(C)	11 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.93 _(π)	15 _($\min$)	5480 _(α^2)		0.90 _(π)	15 _($\min$)	2.2 _(C)	108 _(α)
		$\mathcal{K} = 0.16 \quad \chi^2 = 5480$				$\mathcal{K} = 0.13 \quad \chi^2 = 3530$			
<i>sphère</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.03 _(π)	36 _(μ)	62 _(σ^2)		0.05 _(π)	11 _($\min$)	3.6 _(C)	35 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.97 _(π)	42 _($\min$)	1340 _(α^2)		0.95 _(π)	42 _($\min$)	2.2 _(C)	53 _(α)
		$\mathcal{K} = 0.06 \quad \chi^2 = 2540$				$\mathcal{K} = 0.05 \quad \chi^2 = 3240$			
<i>anneau</i>	$\hat{\Phi}_{y(\text{ombre})}$	0.02 _(π)	39 _(μ)	84 _(σ^2)		0.07 _(π)	11 _($\min$)	1.8 _(C)	60 _(α)
	$\hat{\Phi}_{y(\text{réver.})}$	0.98 _(π)	42 _($\min$)	1530 _(α^2)		0.93 _(π)	48 _($\min$)	1.9 _(C)	50 _(α)
		$\mathcal{K} = 0.06 \quad \chi^2 = 2700$				$\mathcal{K} = 0.06 \quad \chi^2 = 5360$			

TAB. 1.13 – Estimations obtenues par l'algorithme ECI (modèle Gauss-Rayleigh et modèle Weibull-Weibull).




FIG. 1.12 – Histogramme de l'image "cylindre sur sable" et mélange de densités de probabilité estimé avec la procédure ECI. (a) Mélange de deux distributions de Weibull. (b) Mélange de distributions différentes (loi gaussienne pour la répartition des pixels situés dans une zone d'ombre et loi de Rayleigh décalée pour la répartition des pixels dans la zone de réverbération).




FIG. 1.13 – Histogramme de l'image "cylindre sur cailloux" et mélange de densités de probabilité estimé avec la procédure ECI. (a) Mélange de deux distributions de Weibull. (b) Mélange de distributions différentes (loi gaussienne pour la répartition des pixels situés dans une zone d'ombre et loi de Rayleigh décalée pour la répartition des pixels dans la zone de réverbération).

1.11 Conclusion

La modélisation du bruit en imagerie SONAR par des lois de Weibull est intéressante car cette modélisation est très proche de la physique du phénomène observé. Cette modélisation est de plus pertinente pour le caractère non supervisé de notre application, car l'*a priori* (quelquefois faux) que l'on faisait avec la modélisation Gauss-Rayleigh sur la forme des différentes distributions des niveaux de gris associés à chacune des classes, n'existe plus. Contrairement aux algorithmes EM et SEM, l'algorithme ECI permet une estimation efficace des paramètres associés à ce type de modélisation. Les tests sur des images SONAR réelles et synthétiques sont venus confirmer tout l'intérêt de ce type de modélisation, plus juste au sens du critère du χ^2 et de la distance de Kolmogorov qu'une modélisation Gauss-Rayleigh.

Chapitre 2

Estimation des paramètres du modèle *a priori*

Dans ce chapitre, nous nous intéressons au problème d'estimation des paramètres Φ_x du modèle *a priori* (ou modèle du champ d'étiquettes) défini comme étant une distribution de Gibbs. Dans un premier temps, nous rappelons les différents types d'algorithmes existants dans la littérature. Le troisième paragraphe est consacré à l'étude de l'estimateur des *données complètes* proposé par Derin *et al.* [30] (x est supposé observable). Dans le dernier paragraphe, nous présentons une méthode permettant d'estimer conjointement les paramètres du modèle *a priori* (au sens des moindres carrés) avec les paramètres du modèle du bruit (au sens du MV).

2.1 Étude bibliographique

Lorsque x est observable, plusieurs méthodes ont été proposées pour estimer les paramètres d'une distribution de Gibbs.

- la plus connue de ces méthodes est la méthode du codage proposée par Besag [6]. Cette technique est basée sur une estimation au sens du MV et conduit à des paramètres estimés qui maximisent une fonction de vraisemblance, définie comme étant la probabilité des différentes v.a. X_s conditionnellement à la configuration de leurs voisins.
- Une simplification de la méthode du codage a été proposée par le même auteur (méthode MPV ou méthode du Maximum de Pseudo Vraisemblance) et consiste à supposer que les différentes v.a. X_s (conditionnées à la configuration de leurs voisins) sont indépendantes entre elles. Les paramètres estimés maximisent ainsi une fonction appelée fonction de pseudo-vraisemblance.

Ces deux méthodes requièrent la résolution d'un système d'équations non linéaires. Les méthodes numériques itératives utilisées pour résoudre ce problème sont malheureusement très sensibles à la valeur initiale donnée à $\Phi_x^{[0]}$.

- Une autre méthode (méthode LSQR pour Least Square), plus simple, a été proposée par Derin *et al.* [30]. Cette méthode consiste à calculer l'histogramme des différentes configurations possibles du voisinage et à résoudre un système (surdimensionné) d'équations linéaires dont les différents paramètres sont solutions. Bien que la technique d'estimation proposée par Derin *et al.* n'ait pas une signification aussi claire que la méthode du codage (qui estime ces paramètres au sens du MV), les estimations obtenues sont précises et les techniques numériques utilisées pour les trouver (méthode des moindres carrés) ne sont pas itératives.

Les différents estimateurs (MV, MPL, LSQR) utilisent une réalisation x du champ d'étiquettes. Dans notre cas, ce champ est inconnu (c'est en fait précisément l'information que l'on cherche à estimer). Une estimation de Φ_x à partir du champ y , le seul observable, est un problème plus difficile.

- Une solution simple consiste à faire une segmentation courante (SC). Le principe de cette méthode a été expliqué dans le cas de l'estimation des paramètres du modèle du bruit et reste le même pour l'estimation des paramètres Φ_x . Cette technique consiste à interrompre régulièrement le déroulement de la segmentation (effectuée par une stratégie quelconque : MAP, ICM, MPM etc ...) et à utiliser la valeur courante x du champ X afin de ré-estimer Φ_x (par l'un des estimateurs proposés précédemment). Les critiques de cette méthode expliquées pour l'estimation de Φ_y restent cependant valables pour l'estimation de Φ_x .
- Une autre solution consiste à utiliser l'algorithme EM. C'est le cas de l'algorithme EM Gibbsien proposé par Chalmond [18]. Cette technique reprend le principe de l'algorithme EM avec quelques simplifications (notamment l'utilisation de la fonction de pseudo-vraisemblance proposée par Besag). Un autre algorithme qui reprend le principe de l'algorithme EM a été proposé dans [111]. Dans cette référence, cette hypothèse simplificatrice n'est pas prise en compte. Cette méthode utilise le principe de simulation des réalisations de X ainsi qu'un algorithme de descente du gradient pour l'estimation des paramètres Φ_x .
- Une autre méthode consiste à utiliser la procédure générale d'estimation ECI (dont le principe a été expliqué dans le chapitre précédent) et qui, utilisée avec l'un des estimateurs décrit plus haut, permet une estimation de Φ_x optimale au sens de l'erreur quadratique moyenne.

2.2 Estimateur des données complètes du modèle a priori

Le modèle du champ d'étiquettes est défini comme étant une distribution de Gibbs de paramètres Φ_x . Les paramètres de cette distribution de Gibbs, que l'on doit estimer, sont les paramètres des cliques. Pour un système de voisinage du 2nd ordre et un modèle de Potts, ces paramètres sont au nombre de quatre si on ne considère que les cliques binaires ; soit $\beta_1, \beta_2, \beta_3, \beta_4$ qui désignent respectivement le paramètre associé à la clique horizontale, verticale, diagonale droite et gauche respectivement (cf. figure 2.1). Soit s un site, X_{ν_s} l'ensemble des v.a. associées au voisinage de s et η_s , la configuration particulière de ce voisinage. Sous ces conditions, la probabilité associée à la réalisation x du champ d'étiquettes s'écrit :

$$P_X(x) = \frac{1}{Z} \exp \left\{ - \sum_{\langle s, t \rangle} \beta_{st} \mathcal{I}(x_s, x_t) \right\} \quad (2.1)$$

où Z est une constante de normalisation et :

$$\mathcal{I}(z_1, z_2) = \begin{cases} 0 & \text{si } z_1 = z_2, \\ 1 & \text{autrement.} \end{cases}$$




FIG. 2.1 – Voisinage du 2nd ordre et paramètres associés.

2.2.1 Estimateur de Derin *et al.*

Dans [30], Derin *et al.* proposent une démarche originale pour l'estimation des paramètres β_i de cette distribution de Gibbs. Cette méthode n'est pas itérative et les paramètres estimés sont optimaux au sens des moindres carrés. Cette méthode d'estimation peut facilement se résumer de la façon suivante. La loi conditionnelle locale en s est alors :

$$P_{X_s/X_{\nu_s}}(x_s/\eta_s) \propto \exp\left\{-\sum_{t \in \nu_s} \beta_{st} \mathcal{I}(x_s, x_t)\right\} = \exp\left\{-\underbrace{\Theta(x_s/\eta_s)^t \Phi_x}_{U_s(x_s, \eta_s, \Phi_x)}\right\} \quad (2.2)$$

Pour deux valeurs distinctes de x_s , soit $x_s = e_0$, et $x_s = e_1$ mais une configuration identique du voisinage $X_{\nu_s} = \eta_i$, on obtient l'expression suivante :

$$\exp(-U_s(e_1, \eta_i, \Phi_x) + U_s(e_0, \eta_i, \Phi_x)) = \left(\frac{P_{X_s/X_{\nu_s}}(e_1/\eta_i)}{P_{X_s/X_{\nu_s}}(e_0/\eta_i)}\right) \quad (2.3)$$

En prenant le logarithme de cette expression et en utilisant l'expression définie pour U_s (cf. équation (2.2)), on obtient :

$$(\Theta(e_0/\eta_i) - \Theta(e_1/\eta_i))^t \Phi_x = \ln \left(\frac{P_{X_s/X_{\nu_s}}(e_1/\eta_i)}{P_{X_s/X_{\nu_s}}(e_0/\eta_i)}\right) \quad (2.4)$$

où Φ_x est le vecteur de paramètres à estimer. Le modèle étant stationnaire, le rapport $P(e_1/\eta_i)/P(e_0/\eta_i)$ peut être estimé par une technique proche de celle de l'histogramme [30], en comptant le nombre de configurations particulières du voisinage du type (e_1/η_i) apparaissant dans x et en divisant par le nombre de configurations du type (e_0/η_i) . Pour toutes les valeurs possibles de η_i , on obtient une équation linéaire. Pour notre système de voisinage du 2nd ordre, il existe 2^8 configurations différentes du voisinage. On obtient donc 256 équations. Il est important de noter que les configurations qui n'apparaissent pas ne peuvent être utilisées pour obtenir une des équations du système à cause du logarithme de l'expression (2.4). Il en est de même des équations pour lesquelles $\Theta(e_0/\eta_i) = \Theta(e_1/\eta_i)$ (configurations du voisinage symétrique dans la symétrie centrale de centre s) conduisant à une équation du type $0 = C^{st}$. Le vecteur de paramètres à estimer est solution d'un système linéaire surdimensionné qui peut être résolu par une méthode des moindres carrés. Ce système linéaire d'équations peut s'écrire :

$$\underline{A}\Phi_x = b \quad (2.5)$$

avec $\underline{A}$ une matrice non carrée de n équations et 4 inconnues ($n \geq 4$), b un vecteur (ou matrice colonne à n lignes) et Φ_x , le vecteur à estimer. La matrice $\underline{A}$ n'est pas carrée et n'est donc pas inversible. Il existe néanmoins un vecteur Φ_x tel que $\|\underline{A}\Phi_x - b\|$ soit minimal. La technique des moindres carrés permet de trouver ce vecteur et Φ_x s'écrit :

$$\Phi_x = (\underline{A}^t \underline{A})^{-1} \underline{A}^t b \quad (2.6)$$

2.2.2 Résultats expérimentaux

Nous présentons quelques résultats obtenus par la méthode proposée par Derin *et al.* pour l'estimation des paramètres d'une distribution de Gibbs, connaissant une réalisation x de cette distribution. Dans les résultats que nous présentons ici, x est généré par un échantillonneur de Gibbs (50 itérations) et avec des paramètres Φ_x connus pour chaque texture. L'efficacité de la méthode est testée en comparant les valeurs estimées aux valeurs spécifiées pour chaque texture créée. Dans le tableau 2.1, nous présentons les paramètres spécifiés et les estimations obtenues pour différentes textures dont certaines sont présentées en figure 2.2. Les

résultats montrent que la méthode proposée par Derin *et al.* est fiable et conduit à de bonnes estimations. Les paramètres estimés sont très proches des paramètres spécifiés.

texture	Paramètres spécifiés				Paramètres estimés			
	β_1	β_2	β_3	β_4	β_1	β_2	β_3	β_4
<i>tex1</i>	1	1	1	1	0.95	0.83	0.95	0.99
<i>tex2</i>	0.3	0.3	0.3	0.3	0.30	0.29	0.30	0.30
<i>tex3</i>	1	1	-1	1	0.95	0.93	-0.96	1.03
<i>tex4</i>	1	-1	-1	-1	0.88	-0.91	-1.13	-1.01
<i>tex5</i>	1	1	1.5	-0.5	0.88	0.85	1.48	-0.33
<i>tex6</i>	2	2	0	0	1.93	1.94	-0.05	0.01
<i>tex7</i>	1	1	-1	-1	0.97	0.94	-0.99	-1.00
<i>tex8</i>	2	1	-1	-1	1.77	0.94	-0.86	-0.98

TAB. 2.1 – Résultat de l'estimation de Φ_x par l'estimateur des moindres carrés proposé par Derin *et al.*

Les textures synthétiques présentées en figure 2.2 montrent qu'une distribution de Gibbs simple permet de modéliser efficacement les propriétés géométriques, locales et globales des différents champs d'étiquettes que nous serons à même de trouver en imagerie SONAR. L'échantillon représenté à la figure 2.2.a montre des formes inhomogènes comme celles que l'on peut trouver dans une image SONAR segmentée représentant un fond marin de cailloux. La figure 2.2.d montre des formes géométriques comme celles créées par les ombres portées de mines ou d'objets manufacturés. Les figures 2.2.b et 2.2.f montrent des formes homogènes avec une orientation dominante comme les ombres portées créées par les rides ou les dunes de sable.




FIG. 2.2 – Réalisations de distributions de Gibbs avec des paramètres spécifiés (cf. tableau 2.1 pour les valeurs de ces paramètres).

2.3 Estimateur sur données incomplètes du modèle a priori

Lorsque x n'est pas observable, une des méthodes d'estimation des paramètres du modèle *a priori* consiste à utiliser la procédure ECI. Dans ce cas particulier, l'utilisation de l'ECI est possible car :

- On dispose d'estimateurs $\hat{\Phi}_x$ lorsque x est observable. En particulier, nous avons vu précédemment que l'estimateur proposé par Derin *et al.* était optimal au sens des moindres carrés et conduisait à de bonnes estimations.
- On dispose d'une méthode de simulation, valable pour tout $\hat{\Phi}_x$, des réalisations de X selon la loi conditionnelle à $Y=y$. Cette simulation est possible au moyen de procédures itératives de type échantillonneur de Gibbs, si $\hat{\Phi}_y$ (le vecteur de paramètres du modèle du bruit) est fixé ou estimé lors d'une précédente étape.

Partant d'une valeur initiale pour $\Phi_x^{[0]}$, cet algorithme permet de calculer $\hat{\Phi}_x^{[p+1]}$ à partir de $\hat{\Phi}_x^{[p]}$ de la façon suivante :

- On simule n réalisations $(x_{(1)}, \dots, x_{(n)})$ de X selon la distribution *a posteriori* $P_{X/Y, \Phi}(x/y, \Phi)$ grâce à l'échantillonneur de Gibbs et sur la base de $\hat{\Phi}_x^{[p]}$ (et avec Φ_y fixé ou estimé lors d'une précédente étape).
- On utilise l'estimateur des *données complètes* LSQR sur ces différentes images simulées $x_{(i)}$ et on calcule $\hat{\Phi}_x^{[p+1]}$ par la relation :

$$\hat{\Phi}_x^{[p+1]} = \frac{1}{n} [\hat{\Phi}_x(x_{(1)}) + \dots + \hat{\Phi}_x(x_{(n)})]$$

On recommence jusqu'à la réalisation d'un critère d'arrêt. Généralement :

$$\text{si } \hat{\Phi}_x^{[p+1]} \not\approx \hat{\Phi}_x^{[p]} \quad p \leftarrow (p+1)$$

2.4 Estimation conjointe des paramètres

Précédemment, nous avons présenté un algorithme d'estimation des paramètres du modèle *a priori* utilisant la procédure ECI. Cette méthode utilise le principe de simulation des réalisations de X selon la distribution *a posteriori* $P_{X/Y, \Phi}(x/y, \Phi)$ (grâce à l'échantillonneur de Gibbs). Dans cette approche, l'estimation des paramètres du modèle markovien se déroule en deux étapes : la première étape qui consiste à estimer Φ_y , les paramètres du modèle du bruit avec des paramètres Φ_x fixés *a priori*, et la seconde étape qui estime les paramètres du modèle Φ_x en fixant Φ_y . Rappelons cependant que la distribution *a priori* $P_X(x)$ dépend du vecteur de paramètre Φ_x et que la vraisemblance conditionnelle $P_{Y/X}(y/x)$ dépend du vecteur de paramètre Φ_y . De ce fait, la distribution *a posteriori* $P_{X/Y}(x/y) \propto P_X(x)P_{Y/X}(y/x)$ utilisée par l'échantillonneur de Gibbs dépend du vecteur de paramètre $\Phi = (\Phi_x, \Phi_y)$. Toute réalisation de X selon cette distribution *a posteriori* dépend de Φ_x et de Φ_y . La démarche que nous avons adoptée consiste à estimer conjointement ces deux paramètres dans une même procédure d'estimation conditionnelle itérative. A chaque itération, l'ECI simule sur la base des paramètres Φ (obtenus à l'itération précédente) des réalisations de X . Sur chaque réalisation obtenue, on peut calculer les estimateurs MV des *données complètes* pour estimer les paramètres du modèle du bruit, mais aussi les paramètres Φ_x du modèle en utilisant l'estimateur LSQR. Selon le principe de l'ECI, la moyenne de ces estimations permet d'obtenir ensuite les estimés des paramètres Φ_x et Φ_y à l'itération courante.

La démarche de cet algorithme, appelée ECIG dans la suite (pour ECI Global) est résumé dans le tableau 2.2. Les résultats obtenus par cet algorithme pour une modélisation Gauss-Rayleigh et une modélisation Weibull-Weibull sont rassemblés dans les tableaux 2.4 et 2.3. Les expériences montrent que les estimations de Φ_y

obtenues sont meilleures que celles obtenues par l'ECI lorsque les paramètres Φ_x étaient fixés *a priori*. La convergence des paramètres Φ_x pour l'image “*cylindre et cailloux*” est illustrée à la figure 2.3. L'histogramme de l'image “*sphère*” et le mélange de lois de Weibull estimé par la procédure ECI est représenté à la figure 2.4. Le temps de calcul est de l'ordre d'une minute pour l'estimation des paramètres du modèle markovien d'une image de taille 256×256 pixels.

□ **Algorithme ECIG** POUR L'ESTIMATION DES PARAMÈTRES DU MODÈLE MARKOVIAN

 | $\hat{\Phi}^{[0]}$ vecteur de paramètre initial

• Initialisation

- Estimation du mélange de distributions par l'algorithme des K -moyennes (cf. tableau 1.10). Le résultat obtenu est $\Phi_y^{[0]}$.
- Segmentation au sens du MV sur la base des paramètres $\Phi_y^{[0]}$. Le résultat obtenu est $\hat{x}^{[0]}$.

$$\hat{x}_s^{[0]} = \arg \max_{x_s} P_{Y_s/X_s, \Phi_y}(y_s/x_s, \Phi_y^{[0]}) \quad (\forall s \in S)$$

- Estimation de $\Phi_x^{[0]}$ grâce à l'estimateur LSQR sur $\hat{x}^{[0]}$.

$$\hat{\Phi}_x^{[0]} = \hat{\Phi}_x(\hat{x}^{[0]})$$

• Calcul de $\hat{\Phi}^{[p+1]} = (\hat{\Phi}_y^{[p+1]}, \hat{\Phi}_x^{[p+1]})$ à partir de $\hat{\Phi}^{[p]}$.

- Simulation de n réalisations $(x_{(1)}, \dots, x_{(n)})$ de X selon la distribution *a posteriori* $P_{X/Y, \Phi}(x/y, \hat{\Phi}^{[p]})$ grâce à l'échantillonneur de Gibbs et sur la base de $\hat{\Phi}^{[p]}$.
- On utilise les estimateurs MV des *données complètes* sur ces différentes images segmentées $x_{(i)}$ et on calcule $\hat{\Phi}_y^{[p+1]}$ par la relation :

$$\hat{\Phi}_y^{[p+1]} = \frac{1}{n} [\hat{\Phi}_y(x_{(1)}, y) + \dots + \hat{\Phi}_y(x_{(n)}, y)]$$

- On utilise l'estimateur LSQR des *données complètes* sur ces différentes images segmentées $x_{(i)}$ et on calcule $\hat{\Phi}_x^{[p+1]}$ par la relation :

$$\hat{\Phi}_x^{[p+1]} = \frac{1}{n} [\hat{\Phi}_x(x_{(1)}) + \dots + \hat{\Phi}_x(x_{(n)})]$$

On recommence jusqu'à la réalisation d'un critère d'arrêt. Généralement :

$$\text{si } \hat{\Phi}^{[p+1]} \not\approx \hat{\Phi}^{[p]} \quad p \leftarrow (p+1)$$

TAB. 2.2 – Algorithme ECIG pour l'estimation des paramètres du modèle markovien.




FIG. 2.3 – Convergence des paramètres du modèle a priori pour l'image “cylindre et objet” (modélisation Gauss-Rayleigh).




FIG. 2.4 – Histogramme de l'image “sphère” et mélange des lois de Weibull estimé par la procédure ECI.

		Modélisation Weibull-Weibull							
		K -moyennes				Algorithme ECIG			
cylindre sur sable	$\Phi_{y(e_0)}$	0.23 _(\pi)	15 _(min)	2.6 _(C)	54 _(\alpha)	0.06 _(\pi)	15 _(min)	3.3 _(C)	27 _(\alpha)
	$\Phi_{y(e_1)}$	0.77 _(\pi)	42 _(min)	2.4 _(C)	53 _(\alpha)	0.94 _(\pi)	42 _(min)	1.8 _(C)	41 _(\alpha)
	Φ_x	0.9 _(\beta_1)	1.6 _(\beta_2)	-0.2 _(\beta_3)	-0.3 _(\beta_4)	1.0 _(\beta_1)	1.5 _(\beta_2)	-0.2 _(\beta_3)	-0.3 _(\beta_4)
		$\mathcal{K} = 0.06 \quad \chi^2 = 16300$							
cylindre et objet	$\Phi_{y(e_0)}$	0.17 _(\pi)	13 _(min)	1.9 _(C)	50 _(\alpha)	0.05 _(\pi)	13 _(min)	2.2 _(C)	21 _(\alpha)
	$\Phi_{y(e_1)}$	0.83 _(\pi)	37 _(min)	2.4 _(C)	73 _(\alpha)	0.95 _(\pi)	37 _(min)	1.8 _(C)	49 _(\alpha)
	Φ_x	0.9 _(\beta_1)	1.5 _(\beta_2)	-0.2 _(\beta_3)	-0.2 _(\beta_4)	1.2 _(\beta_1)	1.6 _(\beta_2)	-0.3 _(\beta_3)	-0.3 _(\beta_4)
		$\mathcal{K} = 0.08 \quad \chi^2 = 6100$							
cylindre sur cailloux	$\Phi_{y(e_0)}$	0.12 _(\pi)	-1 _(min)	1.1 _(C)	46 _(\alpha)	0.10 _(\pi)	-1 _(min)	1.1 _(C)	11 _(\alpha)
	$\Phi_{y(e_1)}$	0.88 _(\pi)	15 _(min)	2.4 _(C)	122 _(\alpha)	0.90 _(\pi)	15 _(min)	2.2 _(C)	108 _(\alpha)
	Φ_x	1.1 _(\beta_1)	1.5 _(\beta_2)	-0.2 _(\beta_3)	-0.2 _(\beta_4)	1.4 _(\beta_1)	1.6 _(\beta_2)	-0.4 _(\beta_3)	-0.3 _(\beta_4)
		$\mathcal{K} = 0.13 \quad \chi^2 = 3530$							
sphere	$\Phi_{y(e_0)}$	0.03 _(\pi)	11 _(min)	1.1 _(C)	22 _(\alpha)	0.05 _(\pi)	11 _(min)	3.6 _(C)	35 _(\alpha)
	$\Phi_{y(e_1)}$	0.97 _(\pi)	42 _(min)	2.9 _(C)	72 _(\alpha)	0.95 _(\pi)	42 _(min)	2.2 _(C)	53 _(\alpha)
	Φ_x	0.3 _(\beta_1)	0.3 _(\beta_2)	0.3 _(\beta_3)	0.3 _(\beta_4)	0.3 _(\beta_1)	0.3 _(\beta_2)	0.3 _(\beta_3)	0.3 _(\beta_4)
		$\mathcal{K} = 0.05 \quad \chi^2 = 3240$							
anneau	$\Phi_{y(e_0)}$	0.24 _(\pi)	11 _(min)	2.6 _(C)	71 _(\alpha)	0.07 _(\pi)	11 _(min)	1.8 _(C)	60 _(\alpha)
	$\Phi_{y(e_1)}$	0.76 _(\pi)	48 _(min)	2.5 _(C)	64 _(\alpha)	0.93 _(\pi)	48 _(min)	1.9 _(C)	50 _(\alpha)
	Φ_x	0.2 _(\beta_1)	0.2 _(\beta_2)	0.2 _(\beta_3)	0.2 _(\beta_4)	0.3 _(\beta_1)	0.3 _(\beta_2)	0.2 _(\beta_3)	0.3 _(\beta_4)
		$\mathcal{K} = 0.06 \quad \chi^2 = 5360$							

TAB. 2.3 – Estimations des paramètres du modèle markovien obtenues par l'algorithme ECIG pour une modélisation Weibull-Weibull (e_0 désigne l'étiquette associée à la classe ombre et e_1 désigne l'étiquette associée à la classe réverbération).

		Modélisation Gauss-Rayleigh							
		K -moyennes				Algorithme ECIG			
cylindre sur sable	$\Phi_{y(e_0)}$	0.23 _(\pi)	62 _(moy)	223 _(\sigma^2)		0.03 _(\pi)	32 _(moy)	29 _(\sigma^2)	
	$\Phi_{y(e_1)}$	0.77 _(\pi)	42 _(min)	664 _(\alpha^2)		0.97 _(\pi)	39 _(min)	965 _(\alpha^2)	
	Φ_x	0.8 _(\beta_1)	1.6 _(\beta_2)	-0.2 _(\beta_3)	-0.2 _(\beta_4)	1.2 _(\beta_1)	1.6 _(\beta_2)	-0.2 _(\beta_3)	-0.2 _(\beta_4)
						$\mathcal{K} = 0.08 \quad \chi^2 = 23430$			
cylindre et objet	$\Phi_{y(e_0)}$	0.17 _(\pi)	55 _(moy)	286 _(\sigma^2)		0.03 _(\pi)	25 _(moy)	30 _(\sigma^2)	
	$\Phi_{y(e_1)}$	0.83 _(\pi)	37 _(min)	952 _(\alpha^2)		0.97 _(\pi)	35 _(min)	1424 _(\alpha^2)	
	Φ_x	1.0 _(\beta_1)	1.6 _(\beta_2)	-0.3 _(\beta_3)	-0.2 _(\beta_4)	1.7 _(\beta_1)	1.8 _(\beta_2)	-0.5 _(\beta_3)	-0.3 _(\beta_4)
						$\mathcal{K} = 0.1 \quad \chi^2 = 9500$			
cylindre sur cailloux	$\Phi_{y(e_0)}$	0.12 _(\pi)	28 _(moy)	908 _(\sigma^2)		0.07 _(\pi)	04 _(moy)	21 _(\sigma^2)	
	$\Phi_{y(e_1)}$	0.88 _(\pi)	15 _(min)	3240 _(\alpha^2)		0.93 _(\pi)	15 _(min)	5620 _(\alpha^2)	
	Φ_x	1.2 _(\beta_1)	1.4 _(\beta_2)	-0.2 _(\beta_3)	-0.2 _(\beta_4)	1.8 _(\beta_1)	1.9 _(\beta_2)	-0.3 _(\beta_3)	-0.5 _(\beta_4)
						$\mathcal{K} = 0.05 \quad \chi^2 = 8630$			
sphere	$\Phi_{y(e_0)}$	0.03 _(\pi)	41 _(moy)	199 _(\sigma^2)		0.03 _(\pi)	34 _(moy)	40 _(\sigma^2)	
	$\Phi_{y(e_1)}$	0.97 _(\pi)	42 _(min)	972 _(\alpha^2)		0.97 _(\pi)	42 _(min)	1412 _(\alpha^2)	
	Φ_x	0.5 _(\beta_1)	0.4 _(\beta_2)	0.4 _(\beta_3)	0.4 _(\beta_4)	0.6 _(\beta_1)	0.3 _(\beta_2)	0.4 _(\beta_3)	0.3 _(\beta_4)
						$\mathcal{K} = 0.07 \quad \chi^2 = 2390$			
anneau	$\Phi_{y(e_0)}$	0.24 _(\pi)	84 _(moy)	596 _(\sigma^2)		0.02 _(\pi)	41 _(moy)	57 _(\sigma^2)	
	$\Phi_{y(e_1)}$	0.76 _(\pi)	48 _(min)	1070 _(\alpha^2)		0.98 _(\pi)	47 _(min)	1380 _(\alpha^2)	
	Φ_x	0.4 _(\beta_1)	0.4 _(\beta_2)	0.4 _(\beta_3)	0.4 _(\beta_4)	0.6 _(\beta_1)	0.3 _(\beta_2)	0.4 _(\beta_3)	0.4 _(\beta_4)
						$\mathcal{K} = 0.06 \quad \chi^2 = 2600$			

TAB. 2.4 – Estimations des paramètres du modèle markovien obtenues par l'algorithme ECIG pour une modélisation Gauss-Rayleigh (e_0 désigne l'étiquette associée à la classe ombre et e_1 désigne l'étiquette associée à la classe réverbération).

2.5 Conclusion

Dans ce chapitre, nous avons présenté un algorithme permettant d'estimer conjointement les paramètres du modèle du bruit et les paramètres du modèle du champ d'étiquettes dans une même procédure d'estimation conditionnelle itérative (procédure ECI). La précision des estimations obtenues, associée à la convergence rapide de ces estimations permet d'envisager l'utilisation de cet algorithme pour une segmentation non supervisée en deux classes (*ombre/réverbération*).

Conclusion

Dans cette partie, nous avons comparé deux types de modélisation de bruit en imagerie SONAR. La première repose sur un mélange de lois différentes, comprenant utilise une loi gaussienne pour modéliser la répartition des niveaux de gris situés dans une zone d'ombre et une loi de Rayleigh pour modéliser la répartition des niveaux de gris situés dans la zone de réverbération. La seconde, plus général, repose sur un mélange de lois de Weibull. Les tests ont montré qu'une modélisation par lois de Weibull est plus juste (au sens du critère du χ^2 et de la distance de Kolmogorov) qu'une modélisation Gauss-Rayleigh. Cette modélisation est de plus très intéressante pour le caractère non supervisé de notre application car l'*a priori* (quelquefois faux) que l'on faisait avec la modélisation Gauss-Rayleigh sur la forme des différentes distributions des niveaux de gris associées à chacune des classes, n'existe plus. Contrairement aux algorithmes EM et SEM, l'algorithme ECI permet une estimation efficace des paramètres associés à ce type de modélisation. Une solution originale au problème de l'initialisation de cet algorithme d'estimation itératif a été présentée. Cette méthode d'estimation basée sur l'algorithme des K -moyennes permet d'obtenir une bonne première estimation des paramètres du mélange, même avec des mélanges de distributions importants, et permet d'assurer une convergence rapide et efficace de la procédure ECI.

Nous avons présenté enfin une méthode d'estimation permettant d'estimer conjointement les paramètres du modèle du bruit et les paramètres du modèle du champ d'étiquettes dans une même procédure d'estimation conditionnelle itérative. Ces paramètres sont estimés au sens du MV pour le modèle du bruit et au sens des moindres carrés pour le modèle du champ d'étiquettes. Les tests sur des images SONAR réelles et synthétiques sont venus confirmer tout l'intérêt de cet algorithme qui permet d'obtenir une estimation plus juste de ces estimations qu'une estimation non conjointe (au sens de la distance de Kolmogorov et du critère du χ^2). La précision des estimations obtenues ainsi que la convergence rapide de ces paramètres (assurée dans tous les cas testés) permet d'envisager une segmentation non supervisée en deux classes. Celle-ci fera l'objet de la partie suivante de ce document.

Deuxième partie

Segmentation

Introduction

Segmenter une image SONAR par une approche markovienne ou par une autre approche revient à affecter à chaque pixel une des trois étiquettes *ombre*, *réverbération de fond*, *écho*. Si on appelle X le champ des étiquettes, cette opération consiste à estimer le vecteur de variables aléatoires X en fonction des observations Y , l'ensemble des niveaux de gris de l'image, et des paramètres Φ du modèle markovien incluant le modèle de bruit et le modèle *a priori*.

Précédemment, nous nous sommes intéressés à l'estimation non supervisée des paramètres Φ . Nous avons proposé une procédure d'estimation conditionnelle itérative robuste, permettant d'estimer conjointement les deux groupes de paramètres formant Φ , directement à partir de l'image pour une segmentation en deux classes *ombre/réverbération*. Rappelons que dans cette étape de traitement, les pixels de type *écho* et *réverbération de fond* sont regroupés au sein d'une même classe appelée *réverbération*. Ces paramètres sont estimés au sens du Maximum de Vraisemblance pour le modèle de bruit, et au sens des moindres carrés pour le modèle *a priori*. Nous avons testé l'efficacité de cette méthode à l'aide d'images de synthèse et d'images réelles. Dans ce dernier cas, l'efficacité de l'estimation est mesurée au sens du critère du χ^2 et de la distance de Kolmogorov.

Dans cette partie, nous abordons l'estimation du champ d'étiquettes X . Nous verrons dans un premier temps que le problème de l'estimation de X , au sens d'un critère que l'on définira, consiste en fait à trouver la configuration correspondant au minimum d'une fonction d'énergie donnée. La recherche d'un tel minimum est ensuite un problème classique d'optimisation.

Le premier chapitre lié à cette partie présente les algorithmes monoéchelle classiques de segmentation existants. Nous présentons les résultats expérimentaux d'une segmentation en deux classes (*ombre/réverbération*) obtenus par ces algorithmes sur des images SONAR. Le deuxième chapitre est consacré aux approches hiérarchiques et notamment les approches multirésolution et multiéchelle. Dans le troisième chapitre de cette partie, nous présentons un modèle de segmentation *non supervisé* spécifiquement adapté à la segmentation binaire des images SONAR. Son principe repose sur des interactions à la fois spatial et causal en échelle et une stratégie de minimisation multigrille. Des comparaisons expérimentales avec les autres méthodes hiérarchiques sur des images SONAR réelles et synthétiques sont détaillées. Dans le quatrième chapitre, nous nous sommes intéressés à la segmentation trois classes des images SONAR (*ombre/réverbération de fond/écho*). Nous proposons une démarche originale qui utilise la précédente segmentation deux classes et qui tient compte du nombre très peu élevé (et quelquefois de l'absence) de pixels associés à la classe *écho* et des informations *a priori* sur les propriétés physiques de cette classe.

Chapitre 1

Segmentation monoéchelle

Dans les deux premières sections de ce chapitre, nous présentons les principaux estimateurs utilisés pour une segmentation bayésienne ainsi que les algorithmes classiques monoéchelle d'optimisation existants. Le troisième paragraphe est consacré aux résultats expérimentaux obtenus sur des images SONAR synthétiques et réelles.

1.1 Estimation du champ d'étiquettes

Segmenter une image, c'est estimer un ensemble de variables X dites cachées, à partir d'observations Y . Ce problème est en fait un problème d'estimation de la configuration x , et plusieurs estimateurs sont en général envisageables. Une segmentation bayésienne considère comme critère d'estimation le critère (bayésien) de minimisation de l'espérance d'une fonction de coût conditionnellement aux observations :

$$\hat{x} = \arg \min_x E [C(X, x) | Y = y] \quad (1.1)$$

où X est un vecteur aléatoire représentant la solution exacte et $C(X, x)$ représente le prix à payer quand on choisit x alors que la solution exacte est X . Plusieurs estimateurs bayésiens correspondant à des fonctions de coût différentes peuvent être choisis.

1.1.1 Estimateur du MAP

Le MAP est associé à la fonction de coût :

$$C(X, x) = 1 - \delta_X(x) \quad (1.2)$$

où $\delta_X(x)$ est la masse de Dirac en X . Cette fonction de coût pénalisera de la même façon toutes les configurations différentes de X . L'équation (1.1) devient :

$$\hat{x}_{MAP} = \arg \min_x \left\{ \sum_{x' \in E} C(X, x') \cdot P_{X/Y}(x'/y) \right\} \quad (1.3)$$

$$= \arg \min_x \{1 - P_{X/Y}(x/y)\} \quad (1.4)$$

$$= \arg \max_x \{P_{X/Y}(x/y)\} \quad (1.5)$$

$$(1.6)$$

Le MAP revient donc à choisir un estimateur $\hat{x}$ qui maximise $P_{X/Y}(x/y)$. Cette maximisation ne peut être réalisée directement car l'espace des configurations est trop grand. Pour une image de N^2 pixels, avec deux

classes possibles pour x_s , le calcul direct nécessite le calcul de 2^{N^2} probabilités différentes. Malgré tout, l'un des intérêts de ce critère est qu'on peut lui appliquer la règle de Bayes, ce qui donne après simplification :

$$\hat{x}_{MAP} = \arg \max_x \{P_X(x) \cdot P_{Y/X}(y/x)\} \quad (1.7)$$

En notant $V(x, y) \triangleq -\ln P_{Y/X}(y/x)$, et en vertu du théorème d'Hammersley et Clifford, X est markovien et suit une distribution de Gibbs :

$$P_X(x) = \frac{1}{Z} \exp(-U(x)) \quad (1.8)$$

avec $U(x)$, somme des potentiels locaux sur les cliques $c \in \mathcal{C}$, nous avons :

$$\hat{x}_{MAP} = \arg \max_x \left\{ \frac{1}{Z} \exp(-(U(x) + V(x, y))) \right\} \quad (1.9)$$

$$= \arg \min_x \{U(x) + V(x, y)\} \quad (1.10)$$

La recherche d'un tel minimum est ensuite un problème classique d'optimisation. Une solution approchée peut être obtenue soit par des algorithmes déterministes, dont l'algorithme ICM (*Iterated Conditional Modes*) est un exemple, soit par des algorithmes stochastiques comme le RS (*Recuit Simulé*). Le MAP est l'estimateur le plus souvent employé, mais il présente l'inconvénient de pénaliser de la même façon une erreur sur un site et une erreur sur plusieurs sites. Cet inconvénient est corrigé par l'estimateur du Mode des Marginales *a Posteriori* (MPM).

1.1.2 Estimateur du MPM

Cet estimateur est associé à une fonction de coût moins restrictive que celle associée au MAP puisqu'elle pénalise la configuration x *au prorata* du nombre de sites mal étiquetés [69] :

$$C(X, x) = \sum_{s \in S} (1 - \delta_{X_s}(x_s)) \quad (1.11)$$

L'équation (1.1) permet d'écrire :

$$\hat{x}_{MPM} = \arg \min_x \left\{ \sum_{x'} C(X, x') \cdot P_{X/Y}(x'/y) \right\} \quad (1.12)$$

$$= \arg \min_x \left\{ \sum_{x'} \sum_{s \in S} (1 - \delta_{X_s}(x'_s)) \cdot P_{X/Y}(x'/y) \right\} \quad (1.13)$$

$$= \arg \min_x \left\{ \text{Card}(S) - \sum_{s \in S} \sum_{x'} \delta_{X_s}(x'_s) \cdot P_{X/Y}(x'/y) \right\} \quad (1.14)$$

$$= \arg \max_{x_s} \{P_{X_s/Y}(x_s/y)\} \quad (1.15)$$

Le MPM revient donc à choisir un estimateur $\hat{x}$ qui maximise en chaque site s , la probabilité $P_{X_s/Y}(x_s/y)$. On appelle cet estimateur, le Mode des Marginales *a Posteriori* (ou du MPM) Comme pour le MAP le calcul direct de $P_{X_s/Y}(x_s/y)$ est illusoire :

$$P_{X_s/Y}(x_s/y) = \sum_{x_t, t \neq s} P_{X/Y}(x/y) \quad (1.16)$$

Ce calcul peut néanmoins être approché par des techniques de monté carlo, sur la base d'échantillons de la loi a posteriori $P_{X/Y}(x/y)$ (obtenus par un échantillonneur de Gibbs, par exemple).

Soulignons qu'il existe d'autres estimateurs, notamment l'estimateur MF (ou du champ moyen).

1.2 Optimisation

Dans ce paragraphe, nous présentons rapidement les algorithmes d'optimisation monoéchelle, qui sont utilisés lors de la recherche du MAP et du MPM. Pour plus de détails, nous renvoyons le lecteur aux références citées.

1.2.1 Recuit Simulé (RS)

C'est en fait un simulateur de Gibbs combiné à une décroissance de la température [36, 43]. Le but est de trouver la configuration $\hat{x}_{MAP}$ qui maximise la probabilité $P_{X/Y}(\hat{x}_{MAP}/y)$, c'est donc un algorithme stochastique d'optimisation. La démarche est rappelée dans le tableau 1.1 :

□ Algorithme RECUIT SIMULÉ	
T_0	Température initiale
T_{min}	Température finale
$\hat{x}_0$	Configuration initiale aléatoire
$F(\cdot)$	Fonction de décroissance de la température
– $T \leftarrow T_0$	
– $x^{[0]} \leftarrow \hat{x}_0$	
• Calcul de $\hat{x}^{[k+1]}$ à partir de $\hat{x}^{[k]}$:	
$x \leftarrow \hat{x}^{[k]}$	
1. On balaie l'ensemble des sites s (peu importe l'ordre) et :	
• En chaque site s , on calcule $P_{X_s/X_{\nu_s}, Y_s}(x_s/\eta_s, y_s)$ pour chacune des classes possibles :	
$P_{X_s/X_{\nu_s}, Y_s}(x_s/\eta_s, y_s) = \frac{1}{Z_s} \exp \left\{ -\frac{1}{T_k} \left(\sum_{c \in \mathcal{C}} V_c(x_s) + V(x_s, y_s) \right) \right\} \quad (\forall x_s \in \Omega)$	
• On tire l'une des classes x_s selon les probabilités d'appartenance $P_{X_s/X_{\nu_s}, Y_s}$ définies précédemment.	
$\hat{x}^{[k+1]} \leftarrow x$	
2. Faire décroître la température $T_{k+1} = F(T_k)$ et incrémenter l'itération $k = k + 1$.	
3. Retour en 1. jusqu'à la satisfaction d'un critère d'arrêt. Généralement :	
$\text{si } T_k \geq T_{min} \quad \text{retour en 1.}$	

TAB. 1.1 – *Algorithme RS.*

Caractéristique de cette approche

Certains auteurs [36] ont montré que, si la température initiale T_o est assez grande, la décroissance de température assez lente (en $T_o/\log k$), et si le nombre d'itérations tend vers l'infini, la procédure décrite permet de

trouver le minimum global de la fonction d'énergie. On peut remarquer que lorsque la température est élevée, l'algorithme peut accepter des accroissements importants de l'énergie, ce qui permet en particulier de sortir de puits d'énergie assez profonds. Inversement, lorsque la température décroît, ces sauts deviennent de plus en plus rares et le système se stabilise au fond d'un puits. Sans respect strict des conditions de convergence (refroidissement exponentiel et arrêt à temps fini), cet algorithme permet d'atteindre des configurations assez proches du minimum global de la fonction d'énergie.

1.2.2 Iterated Conditional Modes (ICM)

C'est en fait un simulateur de Gibbs à température nulle ($T = 0$) [7, 27] qui permet d'obtenir une solution approchée du MAP. La démarche est résumée dans le tableau 1.2 :

□ Algorithme ICM
$\hat{x}^{[0]}$ Configuration initiale
• Initialisation : on choisit une configuration initiale $\hat{x}^{[0]}$, aussi proche que possible de la configuration optimale. On peut prendre par exemple une segmentation au sens du MV :
$\hat{x}_s^{[0]} = \arg \max_{x_s} \{ P_{Y_s/X_s}(y_s/x_s) \} \quad (\forall s \in S)$
• Calcul de $\hat{x}^{[k+1]}$ à partir de $\hat{x}^{[k]}$:
$x \leftarrow \hat{x}^{[k]}$
1. On balaie l'ensemble des sites s (selon une stratégie de visite de sites) et :
• En chaque site s , on calcule $P_{X_s/X_{\nu_s}, Y_s}(x_s/\eta_s, y_s)$ pour chacune des classes possibles :
$P_{X_s/X_{\nu_s}, Y_s}(x_s/\eta_s, y_s) = \frac{1}{Z_s} \exp \left(- \left(\sum_{c \in \mathcal{C}} V_c(x_s) + V(x_s, y_s) \right) \right) \quad (\forall x_s \in \Omega)$
• On sélectionne la classe x_s qui correspond à la probabilité maximale (i.e., le mode).
$\hat{x}_s = \arg \max_{x_s \in \Omega} \{ P_{X_s/X_{\nu_s}, Y_s}(x_s/\eta_s, y_s) \}$
$\hat{x}^{[k+1]} \leftarrow x$
2. Retour en 1. jusqu'à la réalisation d'un critère d'arrêt. Généralement :
si $\hat{x}_s^{[k+1]} \not\approx \hat{x}_s^{[k]} \quad k \leftarrow k + 1 \quad \text{et retour en 1.}$

TAB. 1.2 – *Algorithme ICM.*

Caractéristique de cette approche

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 la configuration initiale, l'ordre dans lequel on balaie l'image et le critère d'arrêt utilisé. On peut noter que cet algorithme ne possède pas la caractéristique essentielle du RS qui est de visiter plusieurs puits d'énergie avant de se stabiliser dans l'un d'entre eux. Cet algorithme ne réalise qu'une descente dans un puits d'énergie déterminé par la configuration initiale et le mode de balayage de l'image. En ce sens, il n'est adapté qu'à des problèmes pour lesquels on peut disposer d'une configuration initiale convenable (i.e., assez proche de la configuration optimale).

1.2.3 Technique de Monté Carlo (MC) permettant d'approcher le MPM

Le calcul direct des lois marginales (i.e., $P_{X_s/Y}(x_s/y)$) est impossible. Ce calcul peut néanmoins être approché en utilisant des techniques de réalisations de x à l'aide d'un échantillonneur de Gibbs par exemple. Une séquence $(x(0), \dots, x(N))$ est générée par échantillonnage de $P_{X/Y}(x/y)$. Exploitant la loi des grands nombres et après avoir éliminé les k premiers échantillons trop dépendants de la condition initiale, on fait l'approximation suivante :

$$P_{X_s/Y}(x_s/y) \approx \frac{1}{N-k} \sum_{i=k+1}^{i=N} \delta(x_s(i) - x_s) \quad (1.17)$$

$\hat{x}_{MPM}$ est approché par une des étiquettes apparaissant le plus fréquemment dans la séquence $(x(k), \dots, x(N))$. La démarche est résumée dans le tableau 1.3 :

□ Algorithme TECHNIQUE DE MONTÉ CARLO PERMETTANT D'APPROCHER LE MPM	
$\hat{x}_0$	Configuration initiale aléatoire
$(N-k)$	Nombre d'échantillons pris en compte
$x(0) \leftarrow \hat{x}_0$	
• Simulation de $(N+1)$ réalisations $(x(0), \dots, x(N))$ de X grâce à l'échantillonneur de Gibbs. • On approxime en chaque site $\hat{x}_{MPM}$ par l'étiquette apparaissant le plus fréquemment dans la suite des $(N-k)$ dernières configurations.	
$\hat{x}_s = \arg \max_{x_s} \sum_{i=k+1}^N \delta(x_s(i) - x_s)$	

TAB. 1.3 – *Algorithme MPM.*

Caractéristique de cette approche

Cet estimateur se comporte mieux que les estimateurs du MAP lorsque le processus de formation des observations introduit un bruit important (RSB faible).

1.3 Résultats expérimentaux

Dans ce paragraphe, nous présentons les résultats expérimentaux obtenus sur des images réelles et synthétiques, par ces algorithmes de segmentation monoéchelle.

Les images SONAR synthétiques utilisées sont présentées aux figures 1.3.c, 1.3.d. Elles simulent¹ respectivement l'ombre portée que pourrait créer une sphère et un tore reposant sur un fond marin de sable. Les images SONAR réelles utilisées dans ce test sont présentées aux figures 1.2.a, 1.2.b, 1.2.c et représentent respectivement l'ombre portée d'une mine cylindrique sur fond de sable, l'ombre portée d'une mine cylindrique et d'un rocher sur fond de sable et enfin l'ombre portée d'une mine sur un fond marin composé de cailloux et de roches.

1. La forme de l'ombre portée (et de l'écho) est créée par une procédure classique de lancer de rayon. Le bruit de speckle créé dans la zone de réverbération et la partie des ombres est synthétique.

Dans le cas des images réelles ou synthétiques utilisées, les paramètres utilisés (paramètres du modèle du bruit et paramètres liés au terme d'énergie contextuelle) sont ceux estimés par la procédure d'estimation conditionnelle itérative proposée dans la partie précédente.

Pour les images synthétisées, la comparaison visuelle entre l'image initiale (vérité terrain) et l'image segmentée permet de juger qualitativement l'efficacité des algorithmes utilisés. Cette efficacité peut être quantifiée dans le cas de l'ICM et du RS (utilisé pour la recherche de l'estimateur du MAP) par le calcul de l'Hamiltonien correspondant à l'énergie $U(x, y)$ que l'on cherche à minimiser. Pour les images réelles, il est plus difficile de juger de la qualité de la segmentation obtenue. Le calcul de $U(\hat{x}, y)$ pour la solution retenue est donné. Il permet de comparer l'efficacité de ces trois algorithmes quant à la recherche du MAP, mais non de juger de la qualité de la segmentation obtenue (liée aussi à l'estimation des différents paramètres du modèle markovien). Pour notre application, la segmentation sera appréciée visuellement et jugée satisfaisante si, d'une part, les ombres d'objets, qu'ils soient des rochers ou des objets manufacturés, sont bien présentes sur l'image segmentée, et si la segmentation ne présente pas d'artefacts (i.e., des fausses zones classées comme *ombre* dues à l'effet du bruit de speckle). On peut dans ce cas penser que les paramètres du modèle de bruit sont correctement estimés. De plus, si les ombres de rochers présentent un contour relativement chahuté ou aléatoire, correspondant à la réalité, comparativement aux ombres de mines devant présenter des bords plus géométriques, les résultats seront considérés comme adéquats et dans ce cas, les paramètres liés au terme de régularisation sont aussi correctement estimés.

Modèle de bruit utilisé Le modèle de bruit utilisé pour la segmentation des images SONAR réelles est le modèle Weibull-Weibull modifié que nous avons déjà présenté dans la partie I. Ce modèle consiste à associer aux différentes variables aléatoires Y_i dont le niveau de gris est inférieur ou égal à min (correspondant au paramètre de décalage de la loi de Weibull associé à la classe *réverbération*), une probabilité faible mais non nulle d'appartenir à la classe *réverbération*. On peut justifier qualitativement ce modèle si on admet que le bruit électronique s'applique d'une part sur la partie *ombre* mais aussi de fait sur la partie *réverbération*. Un exemple de modèle de bruit utilisé pour la segmentation est représenté en figure 1.1.




FIG. 1.1 – *Modélisation Weibull-Weibull modifiée.*

Mise en œuvre des algorithmes Les différents algorithmes, utilisés dans ce test, balaient l'ensemble des sites de l'image ligne par ligne (balayage dans le sens lexicographique). De plus, pour chaque algorithme, on utilise les options suivantes.

ICM

- La configuration initiale du champ d'étiquettes, $x^{[0]}$, est obtenue par une segmentation au sens du MV.

- Le critère d'arrêt utilisé ici consiste à compter le nombre de modifications d'états lors d'une itération et à s'arrêter si ce nombre est strictement nul.

Technique de Monté Carlo permettant d'approcher le MPM

- La configuration initiale du champ d'étiquettes, $x^{[0]}$, est obtenue à l'aide d'un tirage aléatoire.
- Les dix premières réalisations de X , i.e. $(x(1), \dots, x(10))$, simulées par l'échantillonneur de Gibbs, trop dépendantes de la configuration initiale, ne sont pas prises en compte dans le calcul des probabilités conditionnelles $P_{X_s/Y}(x_s/y)$.
- Le critère d'arrêt est le même que celui de l'ICM.

RS

- La configuration initiale du champ d'étiquettes, $x^{[0]}$, est obtenue à l'aide d'un tirage aléatoire.
- La relaxation stochastique est basée sur l'échantillonneur de Gibbs. La loi de descente en température utilisée est exponentielle : $T(k) = T_0 A^k$ avec T_0 température initiale, A coefficient de décroissance de température et k le numéro de l'itération. Pour nos tests, $T_0 = 100$ et $A = 0.998$.
- On considère que l'algorithme a convergé lorsque la température finale est inférieure à T_{min} . Pour nos tests, $T_{min} = 0.05$.

Interprétation des résultats Les résultats obtenus par les différents algorithmes sont assez semblables pour les images présentées aux figures 1.2.c et 1.3.b, et meilleurs pour le RS (3797 itérations de l'échantillonneur de Gibbs) en ce qui concerne les autres images.

Pour les images 1.2.c et 1.3.b, les énergies finales obtenues par les algorithmes testés sont sensiblement les mêmes. Cela tendrait à prouver que, dans ce cas précis, la fonction d'énergie est dépourvue de minima locaux prononcés. Quelle que soit la méthode employée, on converge assez rapidement vers un minimum proche du minimum global de la fonction d'énergie. Pour notre application et pour ces images, l'utilisation d'un algorithme stochastique tel que le MPM ou le RS (beaucoup plus lent que l'ICM) n'est donc peut être pas justifiée. La segmentation MV donnée à l'ICM comme configuration initiale est assez proche du MAP, et la fonction d'énergie comporte assez peu de minima locaux pour qu'un algorithme déterministe tel que l'ICM soit suffisant. Pour les autres images, des différences notables existent et montrent ainsi que la fonction d'énergie est plus complexe. L'algorithme ICM monoéchelle ne semble pas donner des résultats satisfaisants (la configuration estimée semble trop loin du MAP). Pour ces images, l'utilisation d'un algorithme stochastique, très coûteux en temps de calcul, semble donc nécessaire dans le cadre d'une estimation monoéchelle de x .

Les temps de calcul sont de l'ordre de deux heures pour le RS (*recuit simulé* avec 3797 itérations de l'échantillonneur de Gibbs, et pour une image de taille 256×256 pixels), de cinq minutes pour le MPM et de quelques secondes pour l'ICM ².

1.4 Conclusion

Les résultats montrent que pour certaines images, l'utilisation d'un algorithme déterministe fournit des résultats proches de ceux obtenus par une relaxation stochastique très coûteuse en temps de calcul. Pour ces images, la fonction d'énergie que l'on cherche à minimiser semble comporter assez peu de minima locaux et les résultats donnés par l'ICM sont, de ce fait, satisfaisants.

Pour d'autres images, par contre, les résultats assez différents que l'on obtient suivant que l'on utilise un algorithme déterministe ou stochastique, montrent que la fonction d'énergie est complexe et présente de nombreux minima locaux. L'utilisation d'algorithmes déterministes multiéchelle, particulièrement bien adaptés aux modèles plus complexes pour lesquels la minimisation de la fonction d'énergie est plus difficile, doit être envisagée et fait l'objet du chapitre suivant.

2. Les tests sont réalisés sur station de travail IMB 43P (120Mhz).




FIG. 1.2 – Exemple de segmentations monoéchelles en deux classes (ombre/réverbération) sur des images SONAR réelles. (a)(b)(c) Images SONAR réelles. (d)(e)(f) Résultats de l'algorithme ICM. (g)(h)(i) Résultats de l'algorithme MPM. (j)(k)(l) Résultats de l'algorithme RS.




FIG. 1.3 – Exemple de segmentations monoéchelles en deux classes (ombre/réverbération) sur des image SONAR synthétiques. (a)(b) Vérités terrain des images SONAR synthétiques. (c)(d) Images SONAR synthétiques. (e)(f) Résultats de l'algorithme ICM. (g)(h) Résultats de l'algorithme MPM. (i)(j) Résultats de l'algorithme RS.

Chapitre 2

Méthodes Hiérarchiques

2.1 Introduction

De nombreux travaux en analyse d'image et en vision par ordinateur ont mis en évidence l'intérêt d'une représentation et d'une analyse hiérarchiques des images. Ainsi, dans le cadre d'une estimation bayésienne associée à une modélisation markovienne, de nouvelles classes de modèles statistiques qui associent représentation statistique de l'image et hiérarchisation de l'information ont été proposées. L'introduction de techniques appelées multigrille, multirésolution, multiéchelle (selon le principe utilisé) ou plus généralement *hiérarchiques* a eu, pour objectif premier, de diminuer la complexité calculatoire des algorithmes de relaxation utilisés dans les problèmes d'optimisation. Aujourd'hui, les motivations d'une analyse hiérarchique de l'image sont riches et multiples. Elle permet, bien sûr, de diminuer la complexité calculatoire, mais aussi de diminuer la complexité des problèmes d'optimisation posés (moindre sensibilité aux minima locaux). Elle est aussi utile pour rendre compte de l'information à des niveaux de description différents (pixels, régions, ...). Ces représentations permettent également de propager plus rapidement des interactions entre primitives locales et globales et de conduire à des solutions de meilleure qualité.

Dans ce chapitre, nous présentons dans un premier temps les grandes familles d'approches alliant modélisation markovienne et approche hiérarchique. La seconde partie de ce chapitre est une présentation plus détaillée des différentes méthodes hiérarchiques existantes. Le troisième paragraphe est consacré aux résultats expérimentaux obtenus pour quelques-uns de ces modèles appliqués à l'analyse d'images SONAR.

2.2 Étude bibliographique

Parmi les approches markoviennes hiérarchiques existantes [41, 45], nous avons choisi de distinguer trois grandes classes :

- les familles de modèles markoviens.
- les modèles Markoviens dont la fonction d'énergie est associée à une grille 2D.
- les modèles markoviens sur graphe hiérarchique.

Familles de modèles markoviens

Cette classe regroupe l'ensemble des approches dans lesquelles l'information est hiérarchisée en juxtaposant des modèles (identiques ou différents) entre lesquels des échanges d'informations sont faits par des procédures

d'optimisation adaptées.

- On peut citer la classe mono-modèle dans laquelle les modèles ainsi que les paramètres sont les mêmes à chaque niveau (ou ajustés de façon heuristique). C'est le principe de l'approche multirésolution qui passe par la construction d'une pyramide de données (obtenue par filtrage puis décimation), et l'utilisation d'un même modèle markovien pour chaque niveau de résolution créé [5, 21, 62, 99].
- On distingue aussi la classe multimodèles où les différents modèles markoviens sont alors définis sur des graphes quelconques, associés à des topologies pouvant être différentes d'un niveau hiérarchique à l'autre et mettant en jeu des fonctions de potentielle *a priori* quelconques. C'est le cas du modèle proposé dans [90] qui comprend deux champs aléatoires markoviens couplés, mettant en œuvre deux niveaux d'interprétation et d'abstraction, le niveau pixel et le niveau région [68, 90].

Modèles dont la fonction d'énergie est associée à une grille 2D

L'idée générale de ces modèles consiste à dériver, à partir d'une fonction d'énergie associée à une grille 2D, une série de fonctions d'énergie à différents niveaux de résolution. Un algorithme d'optimisation multigrille portant sur ces différentes fonctions d'énergie est ensuite défini.

- On peut distinguer dans cette classe l'approche par groupe de renormalisation, qui consiste à examiner comment s'exprime la distribution de Gibbs associée à un champ de Markov donné sur un (ou plusieurs) sous-ensemble(s) de sites du réseau initial. En d'autres termes, il s'agit de calculer la distribution marginale de la loi de Gibbs pour le (ou les) sous-ensemble(s) considéré(s) [35, 37, 50, 71].
- On peut citer aussi les approches multiéchelles qui consiste à définir de façon cohérente des modèles markoviens hiérarchiques à partir d'un unique champ markovien initial. Cette procédure définit à chaque échelle une fonction d'énergie qui se déduit du modèle initial, et qui peut s'interpréter comme la fonction d'énergie associée à un modèle markovien grossier. L'intérêt de cette méthode est de conserver le caractère markovien du modèle aux différentes échelles [44, 84].

Modèles markoviens sur graphe hiérarchique

Dans ce modèle, un champ de Markov unique est défini sur un graphe hiérarchique (quadarbre, graphe pyramidal, modèle markovien 3D, ...). Il s'agit d'une part d'exprimer la fonction d'énergie globale (forme des potentiels, paramètres de l'énergie contextuelle), d'autre part d'étudier les algorithmes d'optimisation associés.

- On peut distinguer la classe hiérarchique par arbre dans laquelle le graphe adopté est un arbre. Cette classe conduit à des algorithmes d'estimation non itératifs et donc particulièrement rapides [10, 62, 103].
- On peut citer aussi la classe de modèles markoviens 3D où le champ markovien est défini sur une pyramide de sites comprenant des interactions aussi bien spatiales que verticales (i.e., inter-niveaux) [53, 54, 55, 56, 57, 109].

2.3 Familles de modèles markoviens

2.3.1 Modèle markovien multirésolution (RMR)

C'est le modèle hiérarchique le plus simple. Cette approche nécessite dans un premier temps la construction d'une pyramide de données obtenue à partir des observations initiales. Cette pyramide peut être obtenue par filtrage gaussien, adoucissement quaternaire, (cf. annexe C) pyramide laplacienne ou encore transformée en ondelettes. On cherche ensuite à estimer une pyramide multirésolution d'étiquettes, sachant qu'à chaque

niveau (du plus grossier au plus fin), le modèle markovien utilisé reste le même [5, 21, 62, 98, 99]. Le modèle markovien est utilisé sur des graphes de même type, portant sur les mêmes cliques et avec le même système de voisinage, mais à des niveaux de résolution différents. L'optimisation à chaque niveau de résolution peut être menée de façon déterministe (ICM). L'initialisation des champs d'étiquettes à chaque niveau est faite à partir du résultat obtenu au niveau précédent (par projection). Les paramètres du modèle peuvent varier d'un niveau à l'autre [98], ou être les mêmes, mais en règle générale, il n'existe pas de méthodes de calcul ou d'approximation de ces paramètres comme dans le cas du groupe de renormalisation ou des approches par restriction.




FIG. 2.1 – Structuration pyramidale des étiquettes et des observations.

En résumé, si y^i désigne le champ d'observation au niveau de résolution i , et n le nombre de niveaux de la pyramide, alors la démarche est présentée dans le tableau 2.1.

Caractéristiques de cette approche

Les modèles markoviens multirésolutions utilisés dans ce contexte, sont élaborés de manière heuristique, en particulier en ce qui concerne l'ajustement des différents paramètres en fonction de la résolution. L'apport d'une telle approche, tant du point de vue de la vitesse de convergence que de la qualité des configurations obtenues n'est pas *a priori* démontrable pour un problème donné même si il est souvent constaté.

2.3.2 Approches multimodèles

Dans [90], les auteurs proposent un exemple d'approche multi-modèles. Le modèle utilisé est formé de deux champs aléatoires markoviens couplés, mettant en œuvre deux niveaux d'interprétation et d'abstraction, le niveau pixel et le niveau région. Le niveau région est modélisé par un graphe d'adjacence (RAG ou Region Adjacency Graph) sur les sites régions (à chaque nœud de ce graphe est associé un ensemble de valeurs qui le caractérisent). Deux régions sont considérées comme étant voisines (i.e., adjacentes) si elles partagent une frontière commune. Un système de voisinage η_k est défini sur ce graphe, constitué de l'ensemble des régions adjacentes au nœud k .

- La première étape consiste en une phase de segmentation bayésienne classique au sens du MAP au niveau pixel (niveau 0).

□ **Algorithme** MULTIRÉSOLUTION

- | | |
|-------|--|
| y^i | Champ d'observations au niveau de résolution i |
| x^i | Champ d'étiquettes au niveau de résolution i |
| n | Nombre de niveaux de la pyramide |

1. Construction d'une pyramide multirésolution des données (filtrage puis décimation par exemple).
2. Initialisation : on choisit une configuration initiale $\hat{x}^n$ pour la résolution la plus grossière, obtenue au sens du MV.

$$\hat{x}_s^n = \arg \max_{x_s^n} \{P_{Y_s^n/X_s^n}(y_s^n/x_s^n)\} \quad (\forall s \in S^n)$$

3. Calcul de $\hat{x}^{i-1}$ à partir de la segmentation obtenue à la résolution précédente, i.e., $\hat{x}^i$:
 - Relaxation déterministe : ICM par exemple
 - Le même modèle est adopté pour tous les niveaux de résolution.
 - Pour les niveaux situés en dessous de la résolution la plus grossière, la configuration initiale résulte de la projection de la segmentation obtenue à la résolution précédente.
 - Retour en 3. jusqu'à atteindre le niveau le plus bas de la pyramide.

TAB. 2.1 – *Algorithme multirésolution.*

- Cette phase de segmentation est ensuite interrompue lorsque le nombre de régions devient acceptable pour être représenté au niveau région par un graphe d'adjacence. Une étape de fusion des différentes régions est ensuite effectuée sur le graphe à l'aide d'une fonction d'énergie exprimant la ressemblance entre les différentes régions adjacentes.

Le résultat obtenu au niveau région (niveau 1) est ensuite utilisé pour conforter la segmentation au niveau pixel (niveau 0).

On peut citer aussi l'approche de Thourel *et al.* qui, avec un modèle de voisinage différent suivant le niveau de résolution, vise à enrichir au fur et à mesure la qualité de la segmentation grâce à une régularisation utilisant un modèle "*a priori*" évolutif [23, 24, 98].

2.4 Modèles dont la fonction d'énergie est associée à une grille 2D

2.4.1 Approches par groupe de renormalisation

L'idée maîtresse de la renormalisation est d'examiner comment s'exprime la distribution de Gibbs, associée à un champ de Markov donné, sur un (ou plusieurs) sous-ensemble(s) de sites du réseau initial. En d'autres termes, il s'agit de calculer la distribution marginale de la loi de Gibbs pour le (ou les) sous-ensemble(s) considéré(s). Ceux-ci peuvent être pris comme autant de sites décimés successifs du réseau initial, d'où résulte la loi de transformation multiéchelle de la fonction d'énergie initiale, à condition que chacune des lois marginales obtenues s'exprime comme une distribution de Gibbs [19, 35, 37, 50, 71].

Pour expliciter cette méthode, considérons un champ d'étiquettes X , défini sur une grille rectangulaire S dont on déduit n sous-grilles $S^1, \dots, S^n$ par décimations successives. On définit sur ces grilles des champs d'étiquettes réduits $X^i, i = 1, \dots, n$, d'ensembles de configurations respectifs E^i , par la spécification des

n distributions conditionnelles $P_{X^{i+1}/X^i}(x^{i+1}/x^i)$. Le champ $X^0 = X$ étant connu, chaque champ d'étiquettes X^i se déduit du précédent par l'application d'une transformation au champ précédent. Connaissant $P_{X^{i+1}/X^i}(x^{i+1}/x^i)$, on peut établir une relation de récurrence entre la distribution du champ (X^{i+1}, Y) et celle du champ (X^i, Y) :

$$P_{X^{i+1}, Y}(x^{i+1}, y) = \sum_{x^i \in E^i} P_{X^{i+1}/X^i}(x^{i+1}/x^i) \cdot P_{X^i, Y}(x^i, y) \quad (2.1)$$

Le champ (X, Y) suit une distribution de Gibbs associée à l'Hamiltonien $U = U^0$:

$$P_{X, Y}(x, y) = \frac{1}{Z} \exp\{-U(x, y)\} \quad (2.2)$$

On peut mettre les distributions des champs (X^i, Y) sous une forme analogue :

$$P_{X^i, Y}(x^i, y) = \frac{1}{Z} \exp\{-U^i(x^i, y)\} \quad (2.3)$$

De la relation (2.1), on déduit l'expression de U^{i+1} en fonction de U^i :

$$U^{i+1}(x^{i+1}, y) = -\ln \left\{ \sum_{x^i \in E^i} P_{X^{i+1}/X^i}(x^{i+1}/x^i) \cdot \exp\{-U^i(x^i, y)\} \right\} \quad (2.4)$$

Une fois déduite la fonction d'énergie à pleine résolution, on peut lui associer un algorithme de minimisation multigrille, dont la version la plus courante est de type descendant. On minimise la fonction au niveau le plus grossier, puis l'on projette le résultat au niveau immédiatement inférieur. Une nouvelle optimisation est menée à ce niveau, et le processus est itéré jusqu'à atteindre la pleine échelle.

Caractéristique de cette approche

Cette approche repose sur un principe simple et rigoureux. Elle s'avère malheureusement difficile à exploiter. Les expressions des différentes énergies U^i , $i = 1, \dots, n$, spécifiées par la récurrence (2.4) sont analytiquement inaccessibles, excepté pour certains types de modèles simples tel que le modèle binaire d'Ising.

2.4.2 Modèle markovien multiéchelle (RME)

Dans ce paragraphe, nous présentons l'algorithme multiéchelle proposé par Pérez *et al.*. Pour plus de détails, nous renvoyons le lecteur à la référence [84]. L'idée d'une approche multiéchelle est de résoudre le problème (1.9) dans des espaces de configurations emboîtés, $E^n \subset E^{n-1} \subset \dots \subset E^0 = E$, correspondant à des configurations de plus en plus "fines". Soit $B^i = \{B_k^i\}_{k=1, \dots, N_i}$, une suite de partitions hiérarchisées de S , c'est-à-dire telle que chaque élément B_k^i , $i = n, \dots, 0$ soit formé par la réunion d'éléments de la partition au niveau plus fin précédent B^{i-1} . Par définition, on aura $B^0 = S$, et, dans le cas qui est présenté ci-dessous, les B_k^i sont des blocs carrés réguliers de taille $2^i \times 2^i$ sites. Le sous-ensemble E^i des champs d'étiquettes à l'échelle i est l'ensemble des configurations $x \in E$ constantes sur les blocs B_k^i , ($k = 1, \dots, N_i$).

$$x \in E^i \Leftrightarrow \forall s \in B_k^i \quad x_s = x_k^i, \quad \text{pour} \quad k = 1, \dots, N_i \quad (2.5)$$

x_k^i étant l'étiquette commune à tous les sites du bloc B_k^i pour le champ $x \in E^i$. L'approche proposée consiste à reformuler l'énergie $U(x, y)$ en exploitant la structure particulière des éléments x de E^i . Tout d'abord, notons que le terme d'attache au données $V(x, y)$ peut s'exprimer sous la forme :

$$V(x, y) = \sum_{k=1}^{N_i} V_k^i(x_k^i, y) \quad (2.6)$$

$$\text{avec} \quad V_k^i(x_k^i, y) = \sum_{s \in B_k^i} V_s(x_k^i, y_s) \quad (2.7)$$

si on suppose que $V(x, y)$ s'écrit sous la forme :

$$V(x, y) = \sum_{s \in S} V_s(x_s, y_s) \quad (2.8)$$

Ensuite, on observe qu'une clique c de $\mathcal{C}$ se trouve, (les cliques considérées ici sont binaires pour un voisinage d'ordre deux) soit à l'intérieur d'un bloc B_k^i , on notera alors $\mathcal{C}_k^i$ l'ensemble des cliques incluses dans le bloc B_k^i , soit à cheval sur deux blocs, on notera de même $\mathcal{C}_{k_1, k_2}^i$ l'ensemble des cliques dont les intersections avec $B_{k_1}^i$ et $B_{k_2}^i$ sont non vides et donc incluses dans $B_{k_1}^i \cup B_{k_2}^i$. De plus, la structure de voisinage $\mathcal{G}$ sur S induit une structure de voisinage $\mathcal{G}_B^i$ sur B^i définie par :

$$B_k^i \text{ et } B_l^i \text{ sont voisins} \Leftrightarrow \exists c \in \mathcal{C} \mid c \cap B_k^i \neq \emptyset \text{ et } c \cap B_l^i \neq \emptyset \quad (2.9)$$

On note $\mathcal{C}_B^i$ l'ensemble des cliques associées à ce système de voisinage. Avec ces définitions, on peut alors écrire la forme d'énergie *a priori* $U(x)$ sous la forme :

$$U(x) = \sum_{\{B_k^i\} \in B^i} U_k^i(x_k^i) + \sum_{\{B_{k_1}^i, B_{k_2}^i\} \in \mathcal{C}_B^i} U_{k_1, k_2}^i(x_{k_1}^i, x_{k_2}^i) \quad (2.10)$$

$$\text{avec} \quad U_k^i(x_k^i) = \sum_{c \in \mathcal{C}_k^i} U_c(x) \quad (2.11)$$

$$U_{k_1, k_2}^i(x_{k_1}^i, x_{k_2}^i) = \sum_{c \in \mathcal{C}_{k_1, k_2}^i} U_c(x) \quad (2.12)$$

Il est donc possible de construire une expression de l'énergie totale $U(x, y)$ pour les configurations x^i de E^i .

Modèle multiéchelle et modèle pyramidal

En remarquant d'une part qu'une configuration x de E^i ne présente qu'une seule étiquette x_k^i à estimer par bloc B_k^i , et que d'autre part l'énergie $U(x, y)$ se décompose sur des cliques formées de blocs B_k^i , on peut alors identifier la partition B^i à une grille S^i de N_i sites, où chaque site k de S^i représente le bloc B_k^i de B^i . S^i est naturellement dotée d'un système de voisinage $\mathcal{G}^i$ découlant directement de (2.9). On note $\mathcal{C}^i$ les cliques que ce système engendre. Une configuration x de E^i peut alors s'interpréter comme la réalisation x^i d'un champ d'étiquettes E^i défini sur S^i , où x_k^i est l'étiquette du bloc correspondant au site k de S^i . On obtient finalement une structure pyramidale des primitives dans le sens où chaque grille S^i est quatre fois plus petite que la "précédente" S^{i-1} (cf. figure 2.2). Dans le cas qui est présenté, rappelons que les blocs B_k^i sont des blocs carrés réguliers de taille $2^i \times 2^i$ sites.

Chaque échelle i est entièrement déterminée par la définition de l'énergie à la résolution maximale. Cette énergie s'écrit :

$$U^i(x^i, y) = U^i(x^i) + V^i(x^i, y) \quad (2.13)$$

$$\text{où} \quad V^i(x^i, y) = \sum_{k \in S^i} V_k^i(x_k^i, y) \quad \text{avec } V_k^i() \text{ défini en (2.7)} \quad (2.14)$$

$$\text{et} \quad U^i(x^i) = \sum_{c^i \in \mathcal{C}^i} U_{c^i}(x^i) \quad (2.15)$$




FIG. 2.2 – Structuration pyramidale des étiquettes.

les potentiels $U_{c_i}^i$ se déduisant directement de (2.10). Grâce à cette structure pyramidale, la recherche de solutions dans les espaces E^i , plus petits que E , et les potentiels $U_{c_i}^i$ liés à son système de voisinage se déterminent analytiquement à partir de la donnée des potentiels U_c . Le calcul de $U(x)$ est donc considérablement réduit. Pour ce qui est de $V(x, y)$, notons que les observations utilisées sont toujours celles correspondant à la résolution la plus fine, contrairement au procédé utilisé par les méthodes pyramidales classiques (multi-résolution, cf. figure 2.1). Enfin, la structure pyramidale est exploitée avec une stratégie descendante pour traiter le problème d'optimisation considéré. À partir d'une configuration de départ, on obtient par relaxation déterministe, par exemple avec l'ICM, une solution x^n à l'échelle n . La projection au niveau inférieur de cette solution sert alors d'initialisation à la relaxation à l'échelle $(n - 1)$. Le procédé est reproduit d'échelle en échelle comme l'indique la figure 2.3 jusqu'à atteindre la solution finale $\hat{x}$ au niveau 0.




FIG. 2.3 – Stratégie multiéchelle descendante.

En conclusion, si n désigne le nombre de niveaux de la pyramide, et si les $\beta_1^i, \beta_2^i, \beta_3^i, \beta_4^i$ représentent respectivement les potentiels associés aux cliques horizontales, verticales, diagonales droite et gauche au niveau de résolution i , la démarche est alors celle présentée dans le tableau 2.2.

Caractéristique de cette approche

L'intérêt principal de cette méthode est de permettre la conservation du caractère markovien du modèle pour différentes échelles. Dans le cas d'une fonction d'énergie complexe, présentant de nombreux minima locaux,

l'approche multiéchelle proposée est appropriée. Elle permet de converger rapidement vers une configuration d'une qualité proche qu'un algorithme stochastique monoéchelle de type *recuit simulé* très couteux en temps de calcul, tout en mettant en œuvre une relaxation déterministe.

□ **Algorithme** MULTIÉCHELLE DE PÉREZ ET AL.

x^i Champ d'étiquettes au niveau de résolution i
 n Nombre de niveaux de la pyramide

1. Initialisation : l'ICM à résolution n est initialisée par minimisation du terme V^n (segmentation au sens du MV).

$$x_k^n = \arg \min_{x_k^n \in \Omega} \left\{ \sum_{s \in B_k^n} V_s(x_k^n, y_s) \right\} \quad (k = 1, \dots, N_n)$$

2. Calcul de $\hat{x}^{i-1}$ à partir de $\hat{x}^i$, résultat obtenu au niveau i .

- Relaxation déterministe : ICM

- Pour $i < n$, la configuration initiale résulte de la projection de la solution précédente.
- Les potentiels au niveau de résolution i se déduisent des potentiels au niveau 0 par les relations suivantes déduites de (2.10) :

$$\begin{aligned} \beta_1^i &= q_{hv}^i \beta_1 & \text{et} & & \beta_2^i &= q_{hv}^i \beta_2 \\ \beta_3^i &= q_d^i \beta_3 & \text{et} & & \beta_4^i &= q_d^i \beta_4 \\ \text{avec} \quad q_{hv}^i &= 2^i + 2(2^i - 1) & \text{et} & & q_d^i &= 1 \end{aligned}$$

- Les vraisemblances des observations au niveau de résolution i sont calculées par la relation (2.7).

$$V_k^i(x_k^i, y) = \sum_{s \in B_k^i} V_s(x_k^i, y_s)$$

- Retour en 2. jusqu'à atteindre le niveau le plus bas de la pyramide.

TAB. 2.2 – Algorithme multiéchelle de Pérez et al. [85].

2.5 Modèles markoviens hiérarchiques

2.5.1 Modèle markovien multiéchelle de Bouman

Dans ce paragraphe, nous présentons l'algorithme multiéchelle proposé par Bouman *et al.* Pour plus de détails, nous renvoyons le lecteur à la référence [10]. Dans cet exemple, X et Y sont deux processus aléatoires indicés par les sommets d'un quadarbre ou d'un graphe pyramidal. On considère le processus $X = \{X^i\}_{i=0, \dots, n}$ où n désigne le nombre de niveaux de la pyramide ou du quadarbre. L'hypothèse fondamentale du modèle markovien multiéchelle de Bouman (appelé par la suite MSRF pour MultiScale Random Field) consiste à considérer le processus aléatoire X markovien en échelle, i.e. :

$$P_{X^i/X^j}(x^i/x^j \mid j > i) = P_{X^i/X^{i+1}}(x^i/x^{i+1}) \quad (2.16)$$

Par définition, X^0 représente le champ aléatoire d'étiquettes associé à la segmentation finale. Le conditionnement de Y sur X^0 permet d'écrire :

$$P_{Y/X^i}(y/x^i \ i > 0) = P_{Y/X^0}(y/x^0) \quad (2.17)$$

Et la distribution jointe $P_{X,Y}(x, y)$ peut être exprimée par le produit de ces deux probabilités, ce qui donne après simplifications :

$$P_{X,Y}(x, y) = P_{Y/X^0}(y/x^0) \cdot \left\{ \prod_{i=0}^{n-1} P_{X^i/X^{i+1}}(x^i/x^{i+1}) \right\} \cdot P_{X^n}(x^n) \quad (2.18)$$

Estimateur du SMAP

L'estimateur du MAP est généralement mal adapté aux modèles hiérarchiques. En effet, il pénalise une erreur indépendamment de l'échelle à laquelle elle se produit. L'idéal serait, pour ces modèles, de pénaliser plus sévèrement les erreurs produites aux échelles grossières, puisque la mauvaise classification d'une étiquette à une échelle grossière cause ensuite la mauvaise classification d'un nombre important d'étiquettes à la résolution la plus fine. C'est ce qui est proposé par le SMAP qui est associé à la fonction de coût suivante :

$$C_{SMAP}(X, x) \triangleq \sum_{i=0}^n 2^i \left(1 - \prod_{j=i}^n \delta(X^j - x^j) \right) \quad (2.19)$$

Qualitativement, cette fonction de coût pénalise une segmentation multirésolution au *prorata* de la taille de la plus grande région mal classée. L'estimation de $\hat{x}_{SMAP}$ qui minimise l'espérance de cette fonction de coût conditionnellement aux observations est donnée par :

$$\hat{x}_{SMAP} = \arg \min_x \left\{ \sum_{x'} C(X, x') \cdot P_{X/Y}(x'/y) \right\} \quad (2.20)$$

$$= \arg \max_x \left\{ \sum_{i=0}^n 2^i P_X(x^j \ j > i | Y = y) \right\} \quad (2.21)$$

En utilisant le fait que le processus X est markovien en échelle, les auteurs montrent que l'estimateur bayésien associé à cette fonction de coût est donné avec une bonne précision par :

$$\hat{x}^i \approx \arg \max_{x^i} \{ \ln P_{X^i/X^{i+1}, Y}(x^i/\hat{x}^{i+1}, y) \} \quad (2.22)$$

$$\text{avec} \quad \hat{x}^n \approx \arg \max_{x^n} \{ \ln P_{X^n/Y}(x^n/y) \} \quad (2.23)$$

$\hat{x}^n$ (sommet de la pyramide) est estimé au sens du MAP. La segmentation à chacune des résolutions plus fines est obtenue en calculant une estimation au sens du MAP conditionnée au résultat de la segmentation précédente et à l'observation. En utilisant la règle de Bayes, les propriétés markoviennes de X et en supposant que X^i est uniformément distribué, l'approche récursive précédente peut se réécrire de la façon suivante :

$$\hat{x}^i = \arg \max_{x^i} \{ \ln P_{Y/X^i}(y/x^i) + \ln P_{X^i/X^{i+1}}(x^i/\hat{x}^{i+1}) \} \quad (2.24)$$

$$\text{avec} \quad \hat{x}^n = \arg \max_{x^n} \{ \ln P_{Y/X^n}(y/x^n) \} \quad (2.25)$$

On retrouve dans l'expression (2.24), un terme qui traduit la vraisemblance des observations et un autre qui contient l'information *a priori* du comportement de X , défini ici comme étant markovien en échelle.

Modèle quadarbre

Le premier graphe hiérarchique considéré par Bouman *et al.* est un graphe hiérarchique de type quadarbre (ou quadtree). X et Y sont deux processus aléatoires indicés par les sommets d'un quadarbre (cf. figure 2.4). On note $d(s)$ l'unique père de s . L'ensemble des fils de t est appelé $d^{-1}(t)$. Les sommets de l'arbre qui appartiennent à la même génération forment un ensemble noté S^n où n représente l'échelle. L'échelle 0 correspond à la réalisation la plus fine et l'échelle n , résolution dite la plus grossière, correspond au singleton z , la racine du quadarbre.




FIG. 2.4 – Structure quadarbre utilisée pour le modèle MSRF.

Les auteurs choisissent ensuite la fonction de transition inter-échelles suivante pour exprimer la probabilité que X_s^i égale e_m sachant que son unique *parent* $X_{d(s)}^{i+1}$ égale e_k :

$$P_{X_s^i / X_{d(s)}^{i+1}}(e_m / e_k) = \Theta_{i,0} \delta_m(k) + \frac{1 - \Theta_{i,0}}{K} \quad (2.26)$$

δ_m est la masse de Dirac en m et K le nombre de classes possibles. Le paramètre $\Theta_{i,0} \in [0, 1]$ représente la probabilité que l'étiquette reste la même de l'échelle $(i + 1)$ à l'échelle i . Une propriété importante du quadarbre montrée par Bouman est l'expression de la densité de probabilité $P_{Y/X^n}(y/x^n)$ sous la forme d'un produit de probabilités :

$$P_{Y/X^n}(y/x^n) = \prod_{s \in S^n} P_{Y_s^n / X_s^n}(y_s^n / x_s^n) \quad (2.27)$$

où $\{y_s^n\}$ est l'ensemble des données aux feuilles du sous-arbre de racine $s \in S^n$. En posant : $l_s^i(k) \triangleq \ln P_{Y_s^i / X_s^i}(y_s / k)$ la fonction de vraisemblance, $P_{Y/X^i}(y/x^i)$ aux différents niveaux de la pyramide, peut être calculée récursivement par :

$$l_s^0(k) = P_{Y_s / X_s^0}(y_s / k) \quad (2.28)$$

$$l_s^{i+1}(k) = \sum_{r \in d^{-1}(s)} \ln \left\{ \Theta_{i,0} \exp(l_r^i(k)) + \frac{1 - \Theta_{i,0}}{K} \sum_{m=1}^K \exp(l_r^i(m)) \right\} \quad (2.29)$$

Pour réaliser une segmentation au sens du SMAP, on doit calculer dans un premier temps cette fonction de vraisemblance pour tous les nœuds de l'arbre jusqu'à atteindre le sommet de la pyramide. La seconde étape consiste à résoudre l'équation (2.24) qui est évaluée en maximisant pour chaque nœuds l'expression suivante :

$$\hat{x}_s^i = \arg \max_{1 \leq k \leq K} \left\{ l_s^i(k) + \ln P_{X_s^i / X_{d(s)}^{i+1}}(k / \hat{x}_{d(s)}^{i+1}) \right\} \quad (2.30)$$

Graphe pyramidal

Un inconvénient du modèle quadarbre est qu'il induit des effets de bloc plus ou moins visibles sur les résultats. Afin de réduire ces artéfacts, on peut ajouter des liens inter-échelles, c'est ce qui est proposé dans le graphe pyramidal de la figure 2.5.




FIG. 2.5 – Structure pyramidale utilisée pour le modèle MSRF.

Notons $d(s)$ les parents de site s . Ils sont dans ce cas au nombre de trois. Si i et j désignent respectivement la ligne et la colonne du site s , alors les trois voisins de s à l'échelle supérieure sont :

$$s_1 = ([i/2], [j/2]) \quad (2.31)$$

$$s_2 = ([i/2], [j/2]) + (odd(i), 0) \quad (2.32)$$

$$s_3 = ([i/2], [j/2]) + (0, odd(j)) \quad (2.33)$$

avec $odd(i)$ la fonction qui renvoie 1 si i est impaire et -1 si i est paire. La fonction de transition inter-échelles utilisée pour le modèle pyramidal est la suivante :

$$P_{X_s^i / X_{d(s)}^{i+1}}(e_m / e_l, e_j, e_k) = P_{X_s^i / X_{s_1}^{i+1}, X_{s_2}^{i+1}, X_{s_3}^{i+1}}(e_m / e_l, e_j, e_k) \quad (2.34)$$

$$= \frac{\Theta_{i,1}}{7} \left(3\delta_i(l) + 2\delta_i(j) + 2\delta_i(k) \right) + \frac{1 - \Theta_{i,1}}{K} \quad (2.35)$$

Les auteurs proposent d'utiliser ensuite l'algorithme EM pour estimer les paramètres $\Theta_{i,0}$ et $\Theta_{i,1}$. En conclusion, si n désigne le nombre de niveaux de la pyramide, si $\Theta_{i,0}$ ou $\Theta_{i,1}$ est fixé *a priori*, et si on utilise une structure hybride comme le suggèrent les auteurs, i.e., une structure quadtree pour la phase montante et un graphe pyramidal pour la phase descendante, la démarche est alors présentée dans le tableau 2.3.

□ **Algorithme** MULTIÉCHELLE DE BOUMAN *ET AL.*

x^i	Champ d'étiquettes au niveau de résolution i
K	Nombre de classes
$\Theta_{i,0}$	Probabilité que l'étiquette reste la même de l'échelle i à $(i+1)$ pour le quadarbre
$\Theta_{i,1}$	Probabilité que l'étiquette reste la même de l'échelle $(i+1)$ à i pour le graphe pyramidal

1. Étape montante (modèle quadarbre).

On calcule les fonctions de log-vraisemblance pour tous les sommets de l'arbre jusqu'à atteindre le sommet de l'arbre (grâce aux récurrences (2.28)).

$$l_s^0(k) = P_{Y_s/X_s^0}(y_s/k)$$

$$l_s^{i+1}(k) = \sum_{r \in d^{-1}(s)} \ln \left\{ \Theta_{i,0} \exp(l_r^i(k)) + \frac{1 - \Theta_{i,0}}{K} \sum_{m=1}^K \exp(l_r^i(m)) \right\}$$

2. Initialisation.

On initialise le sommet de la pyramide au sens du MV (relation (2.30)).

$$\hat{x}^n = \arg \max_{x^n} \{l_s^n\} \quad (\forall s \in S^n)$$

3. Étape descendante (modèle pyramidal).

On trouve une approximation du SMAP en résolvant l'équation (2.30) en chaque site, du niveau le plus grossier à la résolution la plus fine :

$$\hat{x}_s^i = \arg \max_{1 \leq k \leq K} \left\{ l_s^i(k) + \ln P_{X_s^i/X_{d(s)}^{i+1}}(k/x_{d(s)}^{i+1}) \right\} \quad (\forall s \in S^n)$$

TAB. 2.3 – *Algorithme du SMAP.*

Caractéristique de cette approche

Cette approche apparaît très attractive puisqu'elle permet d'introduire une régularisation efficace sans recourir à de coûteux algorithmes de relaxation. A titre de comparaison, les résultats sont similaires à ceux obtenus avec un RS pour un coût calculatoire à peu près cent fois moindre.

2.5.2 Modèle hiérarchique de Kato *et al.*

Dans ce paragraphe, nous présentons brièvement le modèle hiérarchique proposé par Kato *et al.* Pour plus de détails nous renvoyons le lecteur à la référence [53]. L'idée proposée par Kato *et al.* est celle d'une modélisation globale de la pyramide multiéchelle. Le modèle markovien 3D introduit porte à la fois sur chacun des niveaux 2D ainsi que sur les interactions entre les niveaux, permettant ainsi une meilleure relation entre les différents niveaux de la pyramide. Le système de voisinage utilisé est un système d'ordre un où on ne considère que les cliques horizontales et verticales. À ces dernières est associé à un même potentiel β (modèle de Potts spatial). Un autre modèle de type Potts gère les interactions entre niveaux exprimés sur une clique ascendante et quatre cliques descendantes, dont les paramètres sont tous égaux à γ sur le même niveau. Le modèle construit est donc un modèle englobant tous les niveaux de résolution. Différentes techniques d'optimisation ont été étudiées, toutes itératives, ICM (déterministe), RS (stochastique) et MTA (recuit simulé multi-températures), et implantées sur une machine massivement parallèle.




FIG. 2.6 – Voisinage utilisé dans le modèle proposé par Kato *et al.*

Kato *et al.* proposent deux méthodes de segmentation. Une supervisée et une autre non supervisée. Dans la première, les paramètres d'attache aux données et des modèles de Potts, spatial et inter-niveaux, sont choisis de manière *ad-hoc* pour la résolution initiale (ou maximale), et déduits selon le principe de l'approche multiéchelle proposée par Pérez *et al.* pour les autres résolutions. Pour la méthode non supervisée proposée par Kato *et al.*, les paramètres d'attache aux données sont estimés par l'algorithme ECI initialisé par la méthode de l'histogramme cumulé. Les paramètres d'énergie contextuelle sont estimés par une technique proche de celle du gradient, applicable ici pour le modèle de Potts utilisé.

Caractéristique de cette approche

Le modèle de base est assez général. On peut utiliser d'autres types de potentiels plus complexes que celui du modèle de Potts spatial présenté ici. Le modèle inter-niveaux est bien adapté à des tâches de segmentation en règle générale, et pourrait être modifié sans affecter le reste de l'approche pour notre application. Par contre, la méthode *non supervisée* proposée, concernant notamment les potentiels d'énergie contextuelle ne

peut être appliquée aux modèles plus complexes que celui de Potts, par exemple à un modèle non isotrope. De plus, même pour un modèle isotrope, cette technique est très coûteuse en temps de calcul et ne peut être appliquée raisonnablement que sur une machine massivement parallèle.

2.6 Conclusion

Parmi les différentes approches que nous avons décrites, certaines semblent intéressantes pour notre application :

- l'approche multirésolution en particulier, bien que heuristique, elle reste facile à mettre en œuvre et peut donner de bons résultats.
- l'approche multiéchelle proposée par Pérez *et al.* qui s'inscrit dans un cadre mathématique bien établi et permet, dans le cas d'une fonction d'énergie complexe présentant de nombreux minima locaux, de converger vers une configuration de bonne qualité.
- enfin, l'approche multiéchelle proposée par Bouman *et al.* et associée à l'estimateur du SMAP, dont la fonction de coût est spécialement adaptée à une segmentation hiérarchique et qui présente l'avantage de la rapidité.

D'autres approches semblent non satisfaisantes ou peu adaptées à notre application :

- soit parce qu'elles sont difficilement exploitables. C'est le cas des modèles s'appuyant sur la théorie du groupe de renormalisation. L'expression des distributions, et donc des fonctions d'énergie, est trop complexe.
- soit parce qu'elles sont trop spécifiques. C'est le cas du modèle non supervisé proposé par Kato *et al.* qui utilise un système de voisinage simplifié (modèle de Pott). Le principe décrit incluant des connections inter-niveaux, est néanmoins assez général et pourra être adapté à notre application comme nous le verrons ultérieurement. Par contre, nous devons trouver une autre approche pour l'estimation non supervisée des paramètres de l'énergie contextuelle, car notre modèle n'est pas isotrope. Le système de voisinage y est plus complexe et comprend des cliques diagonales droite et gauche.

2.7 Résultats des algorithmes hiérarchiques

Dans ce paragraphe nous présentons les résultats expérimentaux obtenus en appliquant les approches multirésolutions et multiéchelles, en particulier celles présentées par Pérez *et al.* et Bouman *et al.* aux images SONAR. L'efficacité des méthodes multirésolution et multiéchelle proposée par Pérez *et al.* ont toutes les deux pour objectif d'approcher plus efficacement le MAP qu'un algorithme monoéchelle déterministe tel que l'ICM. L'efficacité de ces deux méthodes sera quantifiée par le calcul de l'hamiltonien pour la configuration optimale trouvée. Pour l'algorithme proposé par Bouman *et al.*, associé à l'estimateur du SMAP, il sera plus difficile de juger de la qualité de la segmentation obtenue. En effet, on ne dispose pas d'éléments de comparaison, comme précédemment. On ne pourra donc juger de la qualité de la segmentation obtenue que visuellement en comparant l'image initiale et l'image segmentée.

Les paramètres utilisés, paramètres du modèle du bruit et paramètres liés au terme d'énergie contextuelle, sont ceux estimés par la procédure d'estimation conditionnelle itérative proposée dans la partie I. Pour chaque méthode de segmentation utilisée, nous précisons :

- les difficultés de mise en œuvre ainsi que les considérations pratiques associées à chacune des méthodes.
- les résultats expérimentaux obtenus sur les images SONAR synthétiques ou réelles déjà présentées dans le chapitre précédent.

2.7.1 Modèles hiérarchiques associés au MAP

Modèle RMR : L'algorithme est celui que nous avons décrit en 2.3.1. On construit la pyramide d'observations par adoucissement quaternaire et décimation d'ordre deux (cf. annexe).

Modèle RME_{Pérez} : L'estimation multiéchelle est décrite en 2.4.2.

Mise en œuvre des algorithmes

- Le critère d'arrêt utilisé est le même pour les deux algorithmes et pour les différents niveaux de résolution. Il consiste à compter le nombre de modifications d'états lors d'une itération et à arrêter la relaxation déterministe dès que ce nombre est nul.
- L'algorithme ICM est appliqué en balayant l'image dans le sens lexicographique, de gauche à droite et de haut en bas.
- La structuration de la pyramide des étiquettes est faite sur trois niveaux ($n = 3$).

Résultats expérimentaux

Nous présentons les segmentations obtenues par la relaxation multiéchelle proposée par Pérez *et al.* et l'approche multirésolution (cf. figures 2.7, 2.8, 2.9, 2.10, et 2.11).

Les énergies finales obtenues par les deux approches sont sensiblement les mêmes, et sont inférieures à celles obtenues par une relaxation monoéchelle classique déterministe (ICM) ou stochastique (RS). Le résultat est surtout meilleur pour les images dont l'énergie associée est plus complexe (image de la figure 2.8). Une approche multiéchelle ou multirésolution semble particulièrement bien adaptée aux modèles complexes pour lesquels la minimisation de la fonction d'énergie est plus difficile. Dans le cas précis où la fonction d'énergie est dépourvue de minima locaux prononcés (images des figures 2.9 et 2.11), l'amélioration apportée par une approche multirésolution ou multiéchelle n'est pas significative. L'algorithme proposé par Pérez *et al.* est plus rapide que l'algorithme multirésolution, mais dans notre cas précis, les segmentations (et les énergies) obtenues par ces deux méthodes sont sensiblement identiques.

Image de la figure	ICM	RS	RMR	RME
2.7	284691	281425	280324	280325
2.8	297046	294587	293952	293976
2.9	331353	330406	330239	330217
2.10	291376	290538	290138	290197
2.11	295142	294666	294570	294570

TAB. 2.4 – Énergies finales pour les algorithmes associés à la recherche du MAP.

2.7.2 Modèle hiérarchique associé au SMAP

Modèle RME_{Bouman} : L'algorithme est décrit en 2.5.1. Pour une image de taille 256×256 , on construit une pyramide sur trois niveaux. On présente ici la version supervisée de l'algorithme de Bouman. $\Theta_{i,0}$ et $\Theta_{i,1}$ (probabilité que l'étiquette reste la même de l'échelle i à $(i + 1)$ pour le calcul des fonctions de log-vraisemblance et probabilité que l'étiquette reste la même de l'échelle $(i + 1)$ à i pour le graphe pyramidal, sont fixées à 0.99. Les résultats d'une segmentation au sens du SMAP obtenus en calculant les fonctions de log-vraisemblance pour tous les sommets de l'arbre, racine non comprise, soit pour une pyramide sur neuf niveaux (pour une image de taille 256×256) ont donné des résultats quasi identiques.

Résultats expérimentaux

Nous présentons les résultats obtenus par la relaxation multiéchelle proposée par Bouman (cf. figures 2.7, 2.8, 2.9, 2.10, et 2.11). Ne connaissant pas la vérité terrain et n'ayant pas d'éléments de comparaison, comme pour les algorithmes associés au MAP, il est difficile de juger la qualité de la segmentation obtenue. Rappelons toutefois que l'algorithme présenté ici est la version supervisée de celui présenté par Bouman. Les paramètres liés au terme d'énergie contextuelle, représenté par les paramètres $\Theta_{i,1}$ et $\Theta_{i,0}$, ont été fixés *a priori* et de façon optimale pour les images dont nous disposons. La version non supervisée aurait sans doute donné de moins bons résultats.

On peut remarquer, malgré tout, que l'emploi de cliques inter-niveaux, ou plus précisément de probabilités inter-échelles pour un processus défini comme étant markovien en échelle, permet de réduire de façon significative l'effet du bruit de speckle. Par contre, cette méthode induit des effets de bloc plus ou moins visibles sur les résultats. Les contours des objets segmentés semblent assez peu satisfaisants, en comparaison de ceux donnés par l'approche multirésolution ou multiéchelle de Pérez. Pour l'image de la figure 2.7, les contours de la mine que cette segmentation permet d'obtenir sont plus chahutés (et donc moins bons) que ceux donnés par l'approche multirésolution ou multiéchelle. En fait, le modèle utilisé dans cet exemple, i.e., graphe pyramidal avec trois cliques inter-échelles et une seule probabilité de transition est trop simple. Il arrive difficilement à modéliser de façon précise toutes les propriétés du champ d'étiquettes. Le schéma de cliques d'ordre deux, avec un potentiel différent pour chaque clique, utilisé dans la segmentation monoéchelle ou dans la segmentation RMR ou $\text{RME}_{\text{Pérez}}$, est plus apte à modéliser toutes les propriétés locales et globales d'un champ d'étiquettes, telles que l'homogénéité, les propriétés géométriques locales et la directivité. Néanmoins, l'algorithme proposé par Bouman est non itératif et particulièrement rapide par rapport aux algorithmes de relaxation déterministe et stochastique. La possibilité de recourir à des techniques statistiques pour l'estimation des paramètres du modèle, notamment les liens inter-échelles, sans augmenter de façon trop importante le temps de calcul, est également un des points forts de ce modèle.

2.7.3 Complexité calculatoire des algorithmes

Dans le tableau suivant, nous résumons les complexités calculatoires respectives des différents algorithmes monoéchelles ou multiéchelles que nous avons testés. Ces résultats sont présentés en fonction du nombre d'itérations équivalentes réalisées à pleine échelle. Une itération équivalente correspond au balayage complet de l'image à résolution maximale. Les résultats présentés ci-dessous sont valables, pour les algorithmes RD, RMR et $\text{RME}_{\text{Pérez}}$, uniquement pour l'image présentée à la figure 2.9.

ICM	MPM	RS	RMR	$\text{RME}_{\text{Pérez}}$	$\text{RME}_{\text{Bouman}}$
5	60	3797	12.5	7.75	3.5

TAB. 2.5 – Complexité calculatoire des algorithmes d'optimisation en nombre d'itérations équivalentes.




FIG. 2.7 – Exemple de segmentations hiérarchiques sur une image SONAR réelle. (a) Image SONAR réelle. (b) Résultats de l'algorithme SMAP. (c) Résultats de l'algorithme RMR. (d) Résultats de l'algorithme $RME_{Pérez}$.




FIG. 2.8 – Exemple de segmentations hiérarchiques sur une image SONAR réelle. (a) Image SONAR réelle. (b) Résultats de l'algorithme SMAP. (c) Résultats de l'algorithme RMR. (d) Résultats de l'algorithme $RME_{Pérez}$.




FIG. 2.9 – Exemple de segmentations hiérarchiques sur une image SONAR réelle. (a) Image SONAR réelle. (b) Résultats de l'algorithme SMAP. (c) Résultats de l'algorithme RMR. (d) Résultats de l'algorithme $RME_{Pérez}$.




FIG. 2.10 – Exemple de segmentations hiérarchiques sur une image SONAR synthétique. (a) Image SONAR synthétique. (b) Résultats de l'algorithme SMAP. (c) Résultats de l'algorithme RMR. (d) Résultats de l'algorithme $RME_{Pérez}$.




FIG. 2.11 – Exemple de segmentations hiérarchiques sur une image SONAR synthétique. (a) Image SONAR synthétique. (b) Résultats de l'algorithme SMAP. (c) Résultats de l'algorithme RMR. (d) Résultats de l'algorithme $RME_{Pérez}$.

2.8 Conclusion

L'approche RMR ou $\text{RME}_{\text{Pérez}}$ utilisée pour la recherche du MAP permet d'obtenir des améliorations d'autant plus significatives que la fonction d'énergie que l'on cherche à minimiser est complexe. La complexité calculatoire est bien moindre que pour une relaxation stochastique (MC, RS) et les résultats obtenus sont meilleurs dans tous les cas. L'algorithme multiéchelle de Bouman a le mérite d'être très rapide. Le système de voisinage utilisé, très simple ne permet pas, par contre, de modéliser de façon précise toutes les propriétés locales et globales du champ d'étiquettes que l'on cherche à obtenir. Néanmoins, la présence d'un lien inter-niveaux permet de réduire de façon significative l'effet du bruit de speckle présent, à pleine résolution, de façon importante sur certaines images.

L'utilisation d'interactions portant à la fois sur chacun des niveaux 2D et sur les différents niveaux, inspiré du modèle proposé par Kato *et al.* mais adapté à notre application par l'introduction d'un modèle non isotrope, fera l'objet du chapitre suivant.

Chapitre 3

Modèle de segmentation proposé

3.1 Introduction

Les expérimentations décrites au chapitre précédent ont mis en évidence l'intérêt d'une représentation et d'une analyse hiérarchiques des images SONAR. Ce type d'approche permet de diminuer la complexité des problèmes d'optimisation posés par une moindre sensibilité aux minima locaux, ainsi que le coût calculatoire des algorithmes qui leur sont associés. Nous avons vu précédemment qu'un système de voisinage markovien 2D, ou spatial, était indispensable pour modéliser de façon précise toutes les propriétés locales et globales du champ d'étiquettes que l'on cherche à obtenir. Associé à ce système de voisinage, un modèle anisotrope est nécessaire pour traduire certaines propriétés comme la directivité des ombres à extraire des images SONAR de rides ou de dunes de sable. Par contre, les tests précédents ont mis aussi en évidence le fait qu'un modèle markovien utilisant un voisinage purement spatial n'était pas toujours suffisant pour assurer une régularisation efficace, notamment pour certaines images SONAR très bruitées. Pour résoudre ce problème, une solution simple consiste à adopter un système de voisinage plus grand pour chaque site [98]. Malheureusement, cette approche augmente considérablement la complexité de la procédure d'estimation des paramètres du modèle. Une autre approche consiste à définir un modèle markovien en échelle comme celui proposé par Bouman *et al.* [10]. Dans ce modèle, la présence de cliques inter-niveaux permet de réduire efficacement l'effet du bruit de speckle présent sur certaines images. Par contre, le système de voisinage, trop simple (modèle quadarbre ou pyramidal), ne permet pas de modéliser complètement toutes les propriétés locales de l'image et induit des effets de bloc plus ou moins visibles sur les résultats.

Le modèle que nous présentons dans ce chapitre intègre à la fois les spécificités d'un modèle causal et un modèle défini comme étant markovien spatialement. Il s'agit en fait d'une succession de modèles spatiaux liés causalement au sein d'une stratégie d'estimation multigrille [84]. Le premier paragraphe présente ce modèle. Nous décrivons les fonctions d'énergie construites et la stratégie d'optimisation retenue pour notre application. La seconde partie de ce chapitre est consacrée à l'estimation des paramètres de ce modèle. Nous proposons de généraliser la méthode d'estimation proposée par Derin *et al.* pour notre modèle. Des tests sur des images synthétiques permettent de juger de la qualité de l'estimation obtenue par notre méthode. Dans le dernier paragraphe, l'organigramme complet de cet algorithme ainsi que les résultats obtenus sur des images SONAR synthétiques et réelles sont présentés et commentés.

3.2 Modèle Multigrille Causal en Échelle (MCE)

Le principe général reste le même que celui présenté en [84] (cf. paragraphe 2.4.2). Le modèle MCE, Multigrille et Causal en Échelle, ou SCM, Scale Causal Multigrid, que nous introduisons, consiste en une structure pyramidale de champs d'étiquettes $(x^n, \dots, x^0)$, avec $x^0 \equiv x$, dans laquelle le champ d'étiquettes au niveau de résolution i , x^i , d'ensemble de configurations E^i , est défini sur une grille rectangulaire S^i , quatre fois plus petite que la "précédente" S^{i-1} , avec $S^0 \equiv S$. Conditionnellement aux niveaux de résolution supérieurs

et aux données, l'étiquette attachée à un site de S^i interagit avec les étiquettes portées par les sites voisins du même niveau de résolution ainsi qu'avec celle portée par son père. Les observations prises en compte sont toujours celles de la résolution la plus fine. La figure 3.1 décrit la structure pyramidale des champs d'étiquettes et les interactions spatiales et causales utilisées dans notre modèle.




FIG. 3.1 – Structure pyramidale des champs d'étiquettes et interactions utilisées dans la méthode SCM.

L'approche consiste alors à dériver à partir de la probabilité de transition *a posteriori* $P_{X^0/Y, X^1}(x^0/y, x^1)$ au niveau le plus fin, la succession des probabilités de transition *a posteriori* $P_{X^i/Y, X^{i+1}}(x^i/y, x^{i+1})$ aux niveaux supérieurs. Ensuite, la loi *a posteriori* du niveau le plus grossier $P_{X^n/Y}(x^n/y)$ étant donnée (champ markovien spatial), la segmentation peut être déterminée selon le critère du MAP dit séquentiel (SMAP de Bouman *et al* [10]). L'ensemble des segmentations est alors défini de façon descendante par :

$$\hat{x}^n = \arg \max_{x^n} \{P_{X^n/Y}(x^n/y)\} \quad (3.1)$$

$$i = n - 1, \dots, 0 \quad \hat{x}^i = \arg \max_{x^i} \{P_{X^i/Y, X^{i+1}}(x^i/y, \hat{x}^{i+1})\} \quad (3.2)$$

A partir du modèle d'énergie défini à pleine résolution et au niveau de résolution immédiatement supérieur, on dérive ensuite une succession de modèles de résolutions plus grossières. Par l'utilisation des observations y originales, il est possible d'expliciter simplement l'énergie $U^i(x, y)$ associée à ces différents modèles [84]. Chaque échelle i reste entièrement déterminée par la définition de l'énergie à la résolution maximale. Pour notre modèle, cette énergie à la résolution maximale s'écrit :

$$P_{X^0/Y, X^1}(x^0/y, x^1) \propto \exp\{-U^0(x^0, y, x^1)\} \quad (3.3)$$

$$\text{avec } U^0(x^0, y, x^1) = \underbrace{\sum_{s \in S} V_s(x_s, y_s)}_{U(x^0, y)} + \sum_{\langle s, t \rangle} \beta_{st}(1 - \delta(x_s, x_t)) + \sum_{s \in S} \beta_5(1 - \delta(x_s^0, x_{d(s)}^1)) \quad (3.4)$$

où $U(x^0, y)$ désigne la fonction d'énergie à pleine échelle d'un modèle markovien associé à un système de voisinage purement spatial et β_5 représente le paramètre associé au lien causal entre les résolutions 0 et 1.

Soit $\Upsilon^{i,k}$ ($k < i$) la projection de S^i à S^k (cf. figure 2.3), qui associe par duplication, à chaque configuration de S^i , une configuration pour S^k constante sur des blocs carrés réguliers de taille $(2^{i-k} \times 2^{i-k})$. L'approche multigrille [84] permet d'expliciter simplement l'énergie U^i , associée au modèle à la résolution i , à partir de $U^0(x^0, y, x^1)$:

$$P_{X^i/Y, X^{i+1}}(x^i/y, \hat{x}^{i+1}) \propto \exp\{-U^i(x^i, y, \hat{x}^{i+1})\} \quad (3.5)$$

$$\text{avec } U^i(x^i, y, \hat{x}^{i+1}) = U^0(\Upsilon^{i,0}(x^i), y, \Upsilon^{i+1,1}(\hat{x}^{i+1})) \quad (3.6)$$




FIG. 3.2 – Cliques spatiales associées au système de voisinage du second ordre pris en compte dans la méthode SCM et paramètres des potentiels associés.

De (3.4) et (3.6), on déduit :

$$U^i(x^i, y, x^{i+1}) = \sum_{s \in S^i} V_s^i(x_s^i, y_{B_s^i}) + \sum_{\langle s, t \rangle} \alpha_{st}^i \beta_{st} (1 - \delta(x_s^i, x_t^i)) + \sum_{s \in S^i} \alpha_5^i \beta_5 (1 - \delta(x_s^i, x_{d(s)}^{i+1})) \quad (3.7)$$

avec :

$$V_s^i(x_s^i, y_{B_s^i}) = \sum_{p \in B_s^i} V_s(x_s^i, y_p) \quad (3.8)$$

$$\text{et } \alpha_{st}^i = \{\alpha_1^i, \alpha_2^i, \alpha_3^i, \alpha_4^i\} \quad (3.9)$$

avec $y_{B_s^i} = \{y_t \mid t \in B_s^i\}$ l'ensemble des observations contenues dans le bloc carré B_s^i de S , de taille $2^i \times 2^i$ sites, associé au site s de S^i , et β_{st} note $\beta_1, \beta_2, \beta_3$ ou β_4 selon le type de clique binaire $\langle s, t \rangle$ considérée (horizontale, verticale, diagonale droite ou gauche respectivement, cf. figure 3.2). Dans l'expression (3.7), le premier terme est le terme d'attache aux données qui caractérise l'adéquation des étiquettes aux observations pour le niveau de résolution i , le deuxième terme rassemble des interactions spatiales et le troisième terme exprime la dépendance à travers les échelles. En utilisant, l'hypothèse de sous espaces emboîtés et de configurations constantes par bloc (cf. paragraphe 2.4.2), les paramètres de la distribution de Gibbs, $\beta_j^i = \alpha_j^i \beta_j$, $j \in \{1, 2, 3, 4\}$ et le paramètre du lien causal en échelle $\beta_5^i = \alpha_5^i \beta_5$, au niveau de résolution i , se déterminent analytiquement à partir des paramètres β_j à pleine échelle. Pour notre application, on obtient facilement :

$$\alpha_j^i = (2^i + 2(2^i - 1)) \quad j \in \{1, 2\} \quad (3.10)$$

$$\alpha_j^i = 1 \quad j \in \{3, 4\} \quad (3.11)$$

$$\alpha_5^i = 4^i \quad (3.12)$$

Au niveau le plus grossier (sommet de la pyramide), on définit :

$$P_{X^n/Y}(x^n/y) \propto \exp\{-U^n(x^n, y)\} \quad (3.13)$$

$$\text{avec} \quad U^n(x^n, y) = U(\Upsilon^{n,0}(x^n), y) \quad (3.14)$$

La structure pyramidale est ensuite exploitée pour résoudre le problème initial d'estimation correspondant à la relation (3.1). À partir d'une configuration de départ, on obtient par relaxation déterministe ICM une solution $\hat{x}^i$ à l'échelle i (avec $i < n$). La projection $\Upsilon^{i,i-1}(\hat{x}^i)$ au niveau inférieur de cette solution sert alors d'initialisation à la relaxation à l'échelle $i - 1$. Le procédé est alors reproduit d'échelle en échelle comme l'indique la figure 2.3 jusqu'à atteindre la solution finale $\hat{x}$ au niveau 0.

3.3 Estimation des paramètres du modèle SCM

Dans ce paragraphe, nous nous intéressons au problème de l'estimation des paramètres du modèle SCM afin d'obtenir une version non supervisée de l'approche de segmentation proposée.

À ce jour, il existe très peu de méthodes qui proposent d'estimer les potentiels associés aux liens inter-échelles. Dans [10], Bouman *et al.* proposent d'utiliser l'algorithme EM pour l'estimation des liens inter-échelles, mais cette méthode n'est applicable qu'en l'absence d'interactions spatiales. Dans [56], Kato *et al.* utilisent une technique intéressante dans le cas d'un modèle de Potts mais difficilement adaptable à un modèle non isotrope. De plus, même pour un modèle de Potts, cette technique est très coûteuse en temps de calcul (plusieurs minutes sur une machine massivement parallèle). Pour résoudre ce problème d'estimation avec une bonne précision et un temps de calcul relativement faible, nous proposons de généraliser l'estimateur décrit par Derin *et al.* [30] pour estimer les paramètres Φ_x de notre modèle SCM. Nous étudierons la validité et l'efficacité de cette méthode sur des images de synthèse.

3.3.1 Estimateur proposé

En posant $\beta_5 = 0$ et en utilisant les paramètres du modèle du bruit Φ_y et les paramètres Φ_x du modèle *a priori* donnés par la procédure itérative d'estimation ECI proposée dans la première partie de ce document, on peut utiliser l'approche SCM décrite précédemment pour obtenir une première segmentation multiéchelle¹ à partir de laquelle le modèle SCM global, incluant le lien causal inter-échelle, peut être estimé. L'algorithme de segmentation SCM non supervisé se déroule donc en trois étapes (cf. figure 3.4):

1. Une étape d'estimation des paramètres dans laquelle on estime les paramètres du modèle de bruit Φ_y et les paramètres du modèle *a priori* Φ_x associés à un voisinage uniquement spatial, suivi d'une étape de segmentation multiéchelle avec la stratégie décrite au paragraphe 3.2, avec $\beta_5 = 0$.
2. La seconde étape consiste à utiliser cette première segmentation pour estimer les paramètres complets $\Phi_x = (\beta_1, \beta_2, \beta_3, \beta_4, \beta_5)$ du modèle SCM. À cette fin, on utilise une généralisation de la méthode d'estimation proposée par Derin *et al.* On réestime Φ_y au sens du MV en utilisant cette première segmentation.
3. La dernière étape consiste à réaliser une segmentation, sur la base de l'ensemble des paramètres estimés, par l'approche hiérarchique présentée au paragraphe 3.2.

Le vecteur de paramètres $\Phi_x = (\beta_1, \beta_2, \beta_3, \beta_4, \beta_5)$ définissant les paramètres *a priori* du modèle SCM est estimé en généralisant la méthode d'estimation proposée par Derin *et al.* [30]. Cette méthode a déjà été présentée en première partie de ce document dans le cas d'un voisinage purement spatial. L'extension de cette méthode à un système de voisinage spatial et causal en échelle est assez immédiate et consiste à exprimer la relation (I.2.4) pour chaque échelle de la structure pyramidale. Pour simplifier les notations, posons :

1. Dans ce cas, on retrouve l'approche multiéchelle proposée par Pérez [84].

$$P_{X_s/X_{\nu_s}}^i \triangleq P_{X_s^i/X_{\nu_s}^i} \quad (3.15)$$

où ν_s est l'ensemble constitué des huit voisins spatiaux et du père². Notons aussi que $P_{X_s/X_{\nu_s}}^i(x_s/\eta_k)$ est la probabilité d'apparition de l'étiquette x_s avec la configuration particulière du voisinage η_k au niveau de résolution i . Pour notre système de voisinage (huit voisins spatiaux et un lien causal inter-échelle) et une image binaire (deux classes distinctes), il existe 2^9 configurations différentes du système de voisinage. Pour chaque couple (e_0, e_1) , pour chaque niveau de résolution, et pour toutes les valeurs possibles de η_k , on peut former une équation linéaire. Si n désigne le nombre de niveaux de la pyramide, Φ_x est solution du système suivant où chaque équation représente un système linéaire de 2^9 équations :

$$\begin{cases} (\Theta(e_0/\eta_k) - \Theta(e_1/\eta_k)) \underline{M}^0 \Phi_x^t &= \ln \left(\frac{P_{X_s/X_{\nu_s}}^0(e_1/\eta_k)}{P_{X_s/X_{\nu_s}}^0(e_0/\eta_k)} \right) \\ \vdots & \vdots \\ (\Theta(e_0/\eta_k) - \Theta(e_1/\eta_k)) \underline{M}^{n-1} \Phi_x^t &= \ln \left(\frac{P_{X_s/X_{\nu_s}}^{n-1}(e_1/\eta_k)}{P_{X_s/X_{\nu_s}}^{n-1}(e_0/\eta_k)} \right) \end{cases} \quad (3.16)$$

$\underline{M}^i$ est une matrice diagonale où les éléments diagonaux représentent d'une part, les différentes surfaces de contact [84] associées aux cliques respectivement horizontales, verticales, diagonales droite, gauche et d'autre part, le facteur multiplicatif associé au paramètre du lien causal en échelle au niveau de résolution i .

$$\underline{M}^i = \begin{pmatrix} \alpha_1^i & 0 & 0 & 0 & 0 \\ 0 & \alpha_2^i & 0 & 0 & 0 \\ 0 & 0 & \alpha_3^i & 0 & 0 \\ 0 & 0 & 0 & \alpha_4^i & 0 \\ 0 & 0 & 0 & 0 & \alpha_5^i \end{pmatrix} \quad (3.17)$$

Le terme de droite de chacune des équations est empiriquement estimé en calculant le rapport du nombre de configurations distinctes du voisinage de type (e_1/η_k) sur le nombre de configurations distinctes de type (e_0/η_k) et en prenant le logarithme de cette expression. Φ_x est solution d'un système linéaire qui peut être résolu par une méthode des moindres carrés. Le nombre d'équations est variable pour chaque distribution de Gibbs. Il est théoriquement de $n \cdot 2^9$ pour une pyramide de n niveaux. Cependant, on doit noter que les configurations qui n'apparaissent pas ne peuvent être exploitées dans l'obtention des équations du système. Il en est de même des équations pour lesquelles $\Theta(e_0/\eta_k) = \Theta(e_1/\eta_k)$ conduisant à une égalité du type $0 = C^{\text{ste}}$.

3.3.2 Tests sur des images synthétiques

Nous donnons quelques exemples d'estimation de paramètres obtenus par cette méthode d'estimation, appelée LSQR_{3D} par la suite, sur des distributions obtenues par le modèle multigrille et causal en échelle. L'efficacité de la méthode est testée en comparant les valeurs estimées aux valeurs spécifiées pour chaque texture créée.

La création de textures générées par notre modèle SCM ne pose pas de difficultés particulières de mise en œuvre. Il consiste en une succession d'échantillonnage des lois (3.5). La différence avec sa version mono-échelle réside dans le fait que l'échantillonneur de Gibbs ne peut être appliqué à la loi jointe *a priori* $P_{X^0, \dots, X^n}(x^0, \dots, x^n)$, celle-ci n'est en fait pas connue et fait intervenir des interactions à longue distance. Par contre, l'échantillonneur de Gibbs permet de simuler chacune des lois $P_{X^i/X^{i+1}}(x^i/x^{i+1})$ données par l'échantillonnage précédent. En pratique, la synthèse de cette texture requiert une centaine d'itérations à chaque niveau de résolution et la pyramide de champs d'étiquettes comprend trois niveaux ($i = 0, 1, 2$). Pour la méthode LSQR_{3D}, l'algorithme est celui décrit en 3.3.1 et ne pose pas de problèmes de mise en œuvre. On utilise toutes les équations du système (3.16) sauf celles associées à une configuration symétrique ($\Theta(e_0/\eta_k) = \Theta(e_1/\eta_k)$), ainsi que celles associées à une configuration qui n'apparaît pas, ou qui apparaît

2. On qualifiera cet ensemble de système de voisinage bien qu'il s'agit ici d'un abus de langage.

très peu souvent ($N^i(e_l/\eta_k) < 3$ par exemple avec $N^i(e_l/\eta_k)$: nombre de fois qu'apparaît une configuration distincte de type (e_l/η_k) au niveau de résolution i). Dans ce dernier cas, $N^i(e_l/\eta_k)$ est trop faible pour obtenir une bonne estimation de $P_{X_s/X_{\nu_s}}^i(e_l/\eta_k)$. L'erreur faite sur cette probabilité introduit ensuite un biais important dans l'estimation finale des paramètres Φ_x du modèle SCM.

La figure 3.3 présente quelques textures générées par le modèle SCM. Pour $\beta_5 = 0$, soit pour un paramètre associé au lien causal inter-échelle nul, on peut retrouver toutes les distributions de Gibbs mono-échelles classiques au niveau de la pleine résolution. Pour une valeur positive ou négative de ce potentiel, on trouve des textures assez différentes de celles que l'on pouvait créer par un simple système markovien spatial 2D. Les possibilités de modélisation offertes sont ainsi plus larges. Les résultats montrent que les estimations obtenues sont bonnes et que les paramètres estimés sont assez proches des paramètres spécifiés (cf. tableau 3.1). Néanmoins, pour l'image tex7, on peut noter que l'estimation du paramètre associé au lien causal inter-échelle n'est pas très bonne. Soulignons cependant que la texture recrée à partir des paramètres estimés semble posséder des propriétés géométriques locales et globales, telles que l'homogénéité, la directivité, la variabilité spatiale, similaires à celles de la texture originale (cf. figure 3.4).

texture	Paramètres spécifiés					Paramètres estimés				
	β_1	β_2	β_3	β_4	β_5	β_1	β_2	β_3	β_4	β_5
tex1	1	1	-1	-1	1	0.91	0.91	-0.91	-0.90	0.94
tex2	2	1	-1	1	0	1.84	1.04	-0.94	0.84	-0.07
tex3	0.25	0.25	0.25	0.25	0.25	0.26	0.25	0.26	0.26	0.21
tex4	1.5	1.5	0	0	0	1.49	1.56	-0.08	-0.02	0.00
tex5	0.3	0.5	0	0	-0.25	0.31	0.48	-0.03	0.00	-0.25
tex6	1	1	0	0	-1	1.10	0.92	0.13	-0.07	-0.62
tex7	1	1	0	0	0.5	1.09	1.03	-0.03	-0.08	0.20

TAB. 3.1 – Résultats de l'estimation de Φ_x par la méthode LSQR_{3D} sur les textures hiérarchiques présentées à la figure 3.3.

On peut utiliser la méthode LSQR_{3D} pour estimer les paramètres d'un modèle de type SCM comportant plusieurs classes. Cependant, l'estimation risque de ne pas être aussi bonne que pour une simple texture binaire dans le cas d'une image de taille 256×256 pixels. En effet, la probabilité d'apparition de l'étiquette x_s pour une configuration particulière du voisinage η_i est estimée par une technique proche de l'histogramme par le recensement du nombre de fois où ce type de configuration et cette étiquette centrale apparaissent dans l'image. Pour notre système de voisinage comportant neuf voisins (huit voisins spatiaux et un lien causal inter-niveau), et une texture comportant K classes, il existe K^8 probabilités différentes à estimer. Le nombre de fois qu'apparaît dans l'image une étiquette x_s avec une configuration de voisinage particulière η_i devient vite trop faible, dans le cas d'une image de taille 256×256 pixels, pour obtenir une bonne estimation de ces probabilités. Néanmoins, pour une texture comportant trois classes, l'estimation reste encore relativement correcte (cf. figure 3.5).

3.4 Résultats expérimentaux de segmentation

Le synoptique complet de l'algorithme SCM non supervisé est donné dans le tableau 3.4. Les figures 3.7, 3.6, 3.8, 3.9 montrent des segmentations obtenues par cet algorithme sur des images SONAR réelles et synthétiques ainsi que des comparaisons expérimentales avec des segmentations obtenues par d'autres algorithmes de segmentation. Le tableau 3.2 rassemble les paramètres estimés $\hat{\Phi}$ du modèle SCM obtenus par l'étape 3 de l'algorithme (après la première segmentation multi-échelle).

On peut remarquer que les valeurs des paramètres du modèle de bruit $\hat{\Phi}_y$ sont très peu différents de ceux donnés par l'ECI. Pour les paramètres du modèle SCM *a priori*, Φ_x , le système de voisinage étant différent, il est difficile de comparer les valeurs trouvées par cet algorithme avec les valeurs issues de l'algorithme ECI




FIG. 3.3 – Exemples de textures générées par le modèle SCM. Les valeurs des paramètres Φ_x sont données dans le tableau 3.1.




FIG. 3.4 – Textures resynthétisées à partir des paramètres estimés par $LSQR_{3D}$ sur la texture $tex7$.




FIG. 3.5 – Textures comportant trois classes. La texture $tex9$ comprend trois classes, de paramètres $\Phi_x = (0.25, 0.25, 0.25, 0.25)$. Dans ce cas, l'estimation fournit les valeurs suivantes $\hat{\Phi}_x = (0.17, 0.16, 0.17, 0.18, 0.14)$. La texture $tex10$ a pour paramètre $\Phi_x = (1, 1, -1, -1, 1)$. Dans ce cas, l'estimation fournit les valeurs suivantes $\hat{\Phi}_x = (0.7, 0.7, -0.6, -0.6, 0.5)$.

dans le cas d'un voisinage purement spatial. On peut remarquer que la valeur du potentiel associé au lien causal inter-niveau est nulle pour certaines images (cf. tableau 3.2). Dans ce cas, un système uniquement spatial est suffisant pour modéliser toutes les propriétés locales et globales du champ d'étiquettes que l'on cherche à obtenir. Dans ces cas, le modèle SCM proposé permet néanmoins de réestimer plus précisément les paramètres Φ_x du modèle spatial *a priori*.

La planche 3.9 représente en (a) une image SONAR réelle et en (c) un échantillon de la distribution de Gibbs mono-échelle créé à partir des paramètres du système markovien 2D estimés directement sur l'image SONAR par l'algorithme ECI. Nous présentons à côté un échantillon de la texture recréée à partir des paramètres du système SCM issus de l'estimateur LSQR_{3D}. Les textures resynthétisées montrent, dans les deux cas, des formes homogènes, géométriques avec des propriétés locales et globales similaires à celles du champ d'étiquettes que l'on cherche à obtenir. Néanmoins, on peut remarquer que la texture générée par le système de voisinage associé au modèle SCM est plus proche visuellement des formes géométriques que l'on peut trouver sur l'image segmentée (présentée à la figure 3.9.b).

Pour les images synthétiques, une vérité terrain est disponible et nous avons indiqué, dans le tableau 3.3, le taux de bonne classification obtenu pour chacune des différentes techniques de segmentation appliquées à l'image de la figure 3.8. Des taux de bonnes classifications comparables ont été obtenus par les différentes techniques de segmentation appliquées à l'image synthétique de la figure 3.6.c. Ce taux est sensiblement le même pour les méthodes RMR, SMAP ou RME et sensiblement meilleur dans le cas de la méthode SCM.

Pour les images SONAR réelles, une vérité terrain n'est pas disponible et de ce fait, il est difficile d'évaluer la qualité de la segmentation obtenue. Cette appréciation ne peut se faire que visuellement en comparant l'image initiale et l'image segmentée. En particulier, l'image de la figure 3.7 contient un fond marin sableux et une mine dont l'ombre portée a une forme géométrique très simple (un parallélogramme). L'image segmentée obtenue peut être comparée aux segmentations données par les algorithmes ICM, RME, SMAP et RMR. On peut facilement noter qu'il existe, dans le cas de la méthode SCM, moins de fausses zones d'ombre (fausses alarmes) dues à l'aspect granulaire très spécifique du bruit de speckle tout autour de l'ombre portée de la mine. On peut remarquer aussi une forme extraite plus régulière de la mine et donc un contour plus proche de la réalité. Cette efficacité de l'algorithme SCM face au bruit de speckle peut de nouveau se vérifier pour les autres images SONAR réelles (cf. figures 3.6, 3.9).

Figure		paramètres estimés par l'algorithme SCM				
3.7.a	$\Phi_{y(e_0)}$	0.03 _(π)	15 _(min)	3.3 _(C)	23 _(α)	
	$\Phi_{y(e_1)}$	0.97 _(π)	40 _(min)	1.8 _(C)	40 _(α)	
	Φ_x	2.2 _(β_1)	2.6 _(β_2)	-1.0 _(β_3)	-1.0 _(β_4)	0.1 _(β_5)
3.6.b	$\Phi_{y(e_0)}$	0.03 _(π)	13 _(min)	2.2 _(C)	17 _(α)	
	$\Phi_{y(e_1)}$	0.97 _(π)	35 _(min)	1.8 _(C)	48 _(α)	
	Φ_x	2.4 _(β_1)	2.5 _(β_2)	-0.9 _(β_3)	-0.8 _(β_4)	0.0 _(β_5)
3.9.a	$\Phi_{y(e_0)}$	0.10 _(π)	00 _(min)	1.1 _(C)	12 _(α)	
	$\Phi_{y(e_1)}$	0.90 _(π)	14 _(min)	2.2 _(C)	108 _(α)	
	Φ_x	2.3 _(β_1)	2.4 _(β_2)	-0.9 _(β_3)	-1.0 _(β_4)	0.2 _(β_5)
3.8.a	$\Phi_{y(e_0)}$	0.04 _(π)	11 _(min)	3.7 _(C)	31 _(α)	
	$\Phi_{y(e_1)}$	0.96 _(π)	41 _(min)	2.2 _(C)	53 _(α)	
	Φ_x	1.0 _(β_1)	0.8 _(β_2)	0.4 _(β_3)	0.2 _(β_4)	0.0 _(β_5)
3.6.c	$\Phi_{y(e_0)}$	0.02 _(π)	11 _(min)	1.8 _(C)	36 _(α)	
	$\Phi_{y(e_1)}$	0.98 _(π)	45 _(min)	1.9 _(C)	50 _(α)	
	Φ_x	1.1 _(β_1)	0.9 _(β_2)	0.0 _(β_3)	0.3 _(β_4)	0.3 _(β_5)

TAB. 3.2 – Estimation des paramètres du modèle SCM sur des images SONAR synthétiques et réelles.




FIG. 3.6 – Exemple de segmentation SCM en deux classes (ombre/réverbération) sur des images SONAR synthétique et réelles. (a)(b)(c) Images SONAR synthétique et réelles, (d)(e)(f) Segmentation SCM non supervisée.




FIG. 3.7 – Comparaisons expérimentales entre différentes techniques de segmentation sur une image SONAR réelle. (a) Image SONAR réelle. Résultats d'une segmentation en deux classes obtenue avec : (b) ICM, (c) SCM, (d) RMR, (e) SMAP, (f) RME (Technique Multigrille).




FIG. 3.8 – Comparaisons expérimentales entre différentes techniques de segmentation sur une image SONAR synthétique (a) Image SONAR synthétique. Résultats d'une segmentation en deux classes obtenue avec : (b) ICM, (c) SCM, (d) MR, (e) SMAP, (f) RME (Technique Multigrille).

ICM	RMR	RME	SMAP	SCM
98.00	98.88	98.83	98.91	99.15

TAB. 3.3 – Taux de bonne classification obtenu par les différentes techniques de segmentation pour l'image synthétique de la figure 3.8




FIG. 3.9 – Segmentation SCM en deux classes d'une image SONAR réelle et textures monoéchelle et hiérarchique synthétisées à partir de $\hat{\Phi}_x$ estimé par $LSQR_{2D}$ et $LSQR_{3D}$ respectivement. (a) Image SONAR réelle. (b) Segmentation obtenue par la méthode SCM non supervisée. (c) Texture synthétisée à partir des paramètres estimés sur l'image SONAR par l'algorithme ECI et l'estimateur $LSQR_{2D}$. (d) Texture synthétisée à partir des paramètres $\hat{\Phi}_x$ obtenus par l'estimateur $LSQR_{3D}$.

□ **Algorithme SCM NON SUPERVISÉ**

- | | |
|-------|--|
| x^i | Champ d'étiquettes au niveau de résolution i |
| n | Nombre de niveaux de la pyramide |

1. Initialisation : on choisit pour le sommet de la pyramide une configuration obtenue par minimisation du terme V (segmentation au sens du MV).

$$x_k^n = \arg \min_{x_k^n \in \Omega} \left\{ \sum_{s \in B_k^n} V_s(x_k^n, y_s) \right\} \quad (k = 1, \dots, N_n)$$

2. Calcul de $\hat{x}^{i-1}$ à partir de $\hat{x}^i$, résultat obtenu au niveau i ($i \leq n$).

- Relaxation déterministe : ICM

- Pour les niveaux $i \leq n$, la configuration initiale résulte de la projection de la solution précédente ($\hat{x}^i$).
- Les potentiels au niveau de résolution i se déduisent des potentiels au niveau 0 par les relations suivantes :

$$\begin{aligned} \beta_1^i &= q_{hv}^i \beta_1 & \text{et} & & \beta_2^i &= q_{hv}^i \beta_2 \\ \beta_3^i &= q_d^i \beta_3 & \text{et} & & \beta_4^i &= q_d^i \beta_4 \\ \text{avec} \quad q_{hv}^i &= 2^i + 2(2^i - 1) & \text{et} & & q_d^i &= 1 \end{aligned}$$

- Les vraisemblances des observations au niveau de résolution i sont calculées par la relation :

$$V_k^i(x_k^i, y) = \sum_{s \in B_k^i} V_s(x_k^i, y_s)$$

- Retour en 2 jusqu'à atteindre le niveau le plus bas de la pyramide.

3. Estimation des paramètres du modèle SCM

- On applique l'estimateur LSQR_{3D} sur $(\hat{x}^n, \dots, \hat{x}^0)$.

$$\Phi_x = \hat{\Phi}_x(\hat{x}^n, \dots, \hat{x}^0)$$

- On applique les estimateurs MV sur $\hat{x}^0$.

$$\Phi_y = \hat{\Phi}_y(\hat{x}^0, y)$$

4. On réitère les étapes 1 et 2 avec $\Phi = (\Phi_x, \Phi_y)$, et pour le lien causal :

$$\begin{aligned} \beta_5^i &= q_a^i \beta_5 \\ \text{où} \quad q_a^i &= 4^i \end{aligned}$$

TAB. 3.4 – *Algorithme SCM non supervisé.*

3.5 Conclusion

Dans ce chapitre, nous avons présenté un modèle de segmentation associé à des interactions à la fois spatiales et causales en échelle. Dans cette approche, la segmentation d'une image SONAR en deux classes (*ombre/réverbération*) est définie comme étant la solution d'un problème d'estimation bayésienne et causale qui conduit à la minimisation d'une succession d'énergies non linéaires que nous résolvons efficacement grâce à une stratégie multigrille. Le modèle global que nous avons appelé MCE (Multigrille et Causal en Échelle) ou SCM (Scale Causal Multigrid) [79] s'est avéré particulièrement efficace pour la segmentation des images SONAR et notamment pour celles présentant un bruit de speckle important. Nous avons montré également que des interactions spatiales et causales en échelle permettaient de modéliser plus précisément qu'un système markovien uniquement spatial, les propriétés locales et globales du champ d'étiquettes que l'on cherche à estimer. Néanmoins la convergence du modèle vers l'optimum global n'a pas été démontré et reste un problème ouvert. L'estimation des paramètres de ce modèle peut être réalisée efficacement, et sans augmenter de façon trop importante le temps de calcul, (de l'ordre de la minute sur une station IBM 43P pour une image de taille 256×256 pixels) en généralisant l'estimateur proposé par Derin *et al.* [30]. Nous avons illustré ce chapitre de nombreuses comparaisons expérimentales avec d'autres algorithmes hiérarchiques, attestant la validité et la robustesse de la méthode proposée.

Chapitre 4

Segmentation en trois classes

4.1 Introduction

La méthode de segmentation SCM que nous avons proposée dans le chapitre précédent permet de partitionner l'image SONAR en deux zones homogènes : une zone que l'on qualifie d'ombre (et qui résulte de l'absence de réverbération du signal SONAR) et une zone appelée réverbération qui correspond à la réverbération du signal SONAR. Cette segmentation permet d'extraire les ombres des différents objets reposant sur le fond marin. Un système de reconnaissance peut ensuite exploiter la forme de ces ombres pour classer les objets en deux catégories : objets manufacturés ou objets naturels (cf. partie III). Dans notre application, la réverbération constitue donc un phénomène physique sans lequel il n'y a pas de classification possible : c'est en fait son absence (ombre de l'objet) qui constitue le signal utile.

En toute rigueur, la classe *réverbération* peut se subdiviser en deux classes distinctes, i.e., une classe que l'on peut appeler *réverbération de fond* qui correspond à la réverbération du signal SONAR sur le fond marin et une classe appelée *écho* qui correspond à la réverbération du signal SONAR sur les différents objets posés sur le fond marin. Pour cette dernière situation, la réverbération a une intensité maximale. Pour un SONAR classificateur, le contraste écho/réverbération de fond est relativement faible par rapport au contraste *réverbération de fond/ombre*. C'est la raison pour laquelle l'écho de l'objet est formé d'un nombre négligeable de pixels. Cet écho n'est de plus pas toujours discriminant car l'écho d'un rocher peut ressembler à celui d'une mine et réciproquement. Par ailleurs, une mine revêtue d'un revêtement anéchoïde, qui présente un faible indice de réverbération, peut avoir un écho faible et peu caractéristique. Ces raisons motivent l'utilisation de la forme de l'ombre plutôt que l'écho pour l'identification d'un objet reposant sur le fond marin. Néanmoins, même si l'écho ne doit pas constituer le critère déterminant qui permette de détecter, et *a fortiori*, de classer l'objet, il peut représenter une information complémentaire qui peut se révéler utile dans la phase d'interprétation et de classification. Cette information peut permettre de lever une ambiguïté au sujet de la nature de l'objet lorsque l'ombre de celui-ci n'est pas très importante et/ou discriminante, lorsque l'objet est partiellement enfoui par exemple. Dans ces situations, une segmentation en trois classes *ombre/réverbération de fond/écho* des images SONAR peut s'avérer intéressante. Notons aussi qu'une segmentation en trois classes peut être utilisée dans l'optique d'une reconstruction 3D des objets posés sur les fonds marins [108] ou encore en imagerie médicale par ultrasons (ou échographie) [47].

Dans ce chapitre, nous expliquons dans un premier temps pourquoi une approche markovienne classique ne peut être utilisée pour segmenter directement une image SONAR en trois classes (*ombre/réverbération de fond/écho*). Dans le deuxième paragraphe, nous présentons la stratégie de segmentation en trois classes que nous proposons. Dans le troisième paragraphe, nous donnons les résultats obtenus sur des images SONAR synthétiques et réelles.

4.2 Formulation du problème

A cause du nombre peu élevé de pixels associés à la classe *écho*, les algorithmes mono-échelle ou hiérarchiques que nous avons proposés ne peuvent être utilisés pour segmenter efficacement une image SONAR en trois

classes. Cette présence très parcimonieuse d'échos dans l'image peut gêner considérablement une approche markovienne non supervisée. Des problèmes peuvent intervenir à plusieurs niveaux.

Initialisation Cette étape, on le rappelle, permet d'initialiser la procédure ECI pour l'estimation conjointe des paramètres du modèle du bruit, au sens du MV, et des paramètres du modèle *a priori*, au sens des moindres carrés. Elle est basée sur l'algorithme des K-moyennes utilisé pour regrouper différentes petites zones de l'image en K sous-ensembles selon un critère de *ressemblance*. Les estimateurs MV sont ensuite exploités sur les K classes ainsi identifiées.

- L'algorithme utilisé permet très facilement de distinguer les deux classes *ombre/reverbération* dans l'image. Par contre, il ne permet pas de distinguer une troisième classe qui corresponde à l'*écho* de l'objet. Nous avons représenté à la figure 4.1 une image SONAR réelle et la partition obtenue par l'algorithme des K-moyennes pour $K=3$. On peut remarquer que la classe *ombre* est toujours présente. Par contre, la classe *réverbération* a été subdivisée en deux classes : une partie sombre, dans la partie supérieure de l'image, et une autre de niveaux de gris et de variance plus faibles, dans la partie inférieure. Ceci peut s'expliquer par le disfonctionnement du CAG (Contrôle Automatique de Gain) du système SONAR utilisé pour compenser l'atténuation du signal SONAR. Cette atténuation n'a été que partiellement compensée : le signal de réverbération du fond n'est pas stationnaire et présente une amplitude décroissante en fonction de la distance.




FIG. 4.1 – Segmentation en trois classes d'une image SONAR réelle par l'algorithme des K-moyennes. (a) Image SONAR réelle, (b) Segmentation en trois classes obtenue par l'algorithme des K-moyennes.

- En admettant que l'on obtienne une image partitionnée en trois classes, que ce partitionnement soit correct et qu'il corresponde aux différentes classes *ombre/réverbération de fond/écho* de l'image SONAR, un autre problème est de trouver une loi théorique pour représenter la répartition des niveaux de gris associés à la classe *écho* et ensuite de définir les estimateurs MV associés à cette loi. Pour certaines images où cette classe est quasi-inexistante, le nombre de pixels associés à la classe *écho* est trop faible pour que l'estimation des paramètres associés à cette loi puisse être faite avec une bonne précision. Une mauvaise initialisation peut ensuite compromettre la convergence de la procédure d'estimation des paramètres.

Estimation Conditionnelle Itérative (ECI)

- Les tests présentés en [72] ont montré que cet algorithme, au même titre que les algorithmes SEM et EM, a quelques difficultés pour converger vers une solution acceptable lorsque le modèle du bruit théorique ne correspond pas physiquement au phénomène observé, c'est à dire lorsque la loi utilisée pour modéliser la répartition des niveaux de gris associés à cette classe est trop éloignée de la réalité.

En particulier, les résultats présentés en [72] ont montré qu’une modélisation “Gauss-Gauss”, pour une segmentation en deux classes, *ombre/réverbération*, n’était que rarement possible. Si la loi utilisée pour modéliser la classe *écho* n’est pas adaptée, la convergence de l’algorithme peut être compromise.

- Un deuxième problème peut intervenir lors du calcul de l’estimation du modèle *a priori*. Les tests présentés en [72] ont montré que l’estimateur proposé par Derin *et al.* donnait de bons résultats sur une image binaire, soit comportant deux classes. Cependant, l’estimation risque de ne pas être aussi bonne pour une image ternaire, comportant trois classes, notamment lorsqu’une classe est faiblement représentée. En effet, pour un système markovien spatial comportant huit voisins et une estimation faite sur une texture comportant trois classes, il existe 3^8 probabilités différentes à estimer. A cause du faible nombre de pixels associés à la classe *écho*, un nombre important de configurations avec un ou plusieurs voisins appartenant à cette classe ne sont pas représentées et l’estimation obtenue s’en trouve donc biaisée.

Segmentation SCM

- Pour les mêmes raisons que celles présentées précédemment, l’estimateur $LSQR_{3D}$ que nous avons proposé pour estimer les paramètres du modèle markovien SCM, peut conduire également à des estimations biaisées pour certaines images, notamment celles pour lesquelles l’écho est quasi-inexistant.
- De plus, le nombre de pixels associés à la classe *écho*, déjà très faible au niveau de pleine résolution, ne peut être que plus faible encore aux niveaux de résolution inférieure. L’approche hiérarchique utilisée et la présence d’un lien inter-échelle peut conduire à ne pas mettre en évidence cette classe au niveau de pleine résolution.

Pour toutes ces raisons, une segmentation hiérarchique associée à une procédure d’estimation des paramètres n’est pas adaptée à la recherche simultanée des trois classes *ombre/réverbération de fond/écho*. On doit adopter une autre approche pour résoudre ce problème.

4.3 Modèle de segmentation en trois classes

4.3.1 Introduction

Une segmentation markovienne reste néanmoins intéressante car le formalisme utilisé permet conjointement de modéliser statistiquement le lien existant entre les observations et les primitives recherchées et d’introduire des connaissances *a priori* sur ces primitives. Dans notre cas, cette capacité à intégrer des informations *a priori* sur les étiquettes associées à la classe *écho* est très intéressante.

- Le terme d’énergie contextuelle ou terme *a priori* qui spécifie les propriétés statistiques du champ des étiquettes peut contraindre la cohérence spatiale de l’image et privilégier des partitions en régions spatialement homogènes. Grâce à ce formalisme et à des potentiels d’interactions locales adéquats, un pixel de niveau de gris élevé mais isolé dans une zone de réverbération de fond sera considéré à juste titre comme du bruit de speckle, et classé comme *réverbération de fond*.
- Pour la classe *écho*, il existe une autre information *a priori* qu’il faut prendre en compte : un objet posé sur le fond marin crée sur une image SONAR une ombre et un écho. En toute rigueur, un écho ne peut exister que si une ombre se trouve à proximité. On peut quantifier cette assertion par une notion de probabilité et donc d’énergie. Pour une même intensité, un pixel doit avoir d’autant plus de chance d’appartenir à la classe *écho* qu’il se trouve près d’une zone d’ombre et que cette zone d’ombre est importante.

Pour intégrer au mieux dans le formalisme de segmentation markovienne ces informations *a priori*, nous proposons de construire un schéma de segmentation en deux étapes. Il est en effet nécessaire d’établir une

première segmentation de l'image SONAR en deux classes *ombre/réverbération* afin de connaître l'emplacement des *ombres* et de modéliser ensuite la dépendance spatiale entre l'ombre et l'écho par une probabilité (ou d'un terme d'énergie). Dans cette première segmentation en deux classes, les pixels d'intensité maximale correspondant à la classe *écho* recevront l'étiquette *réverbération*. Nous avons choisi dans un deuxième temps de ne pas remettre en cause les étiquettes associées à la classe *ombre* et de segmenter la zone associée à la classe *réverbération* en deux classes, *écho* et *réverbération de fond*.

4.3.2 Stratégie de segmentation en trois classes

Soit $\hat{x}^{[1]}$, le champ d'étiquettes associé à la segmentation en deux classes *ombre/réverbération* obtenu par le modèle de segmentation SCM. L'étiquette $\hat{x}_s^{[1]}$ prend ses valeurs dans $\{e_0, e_1\}$. Partant de $\hat{x}^{[1]}$, nous considérons maintenant le sous-ensemble de pixels S' ($S' \subset S$) tel que $S' = \{s \in S : \hat{x}_s^{[1]} = e_1\}$. Cet ensemble de pixels doit être maintenant segmenté en deux classes, *écho* et *réverbération de fond*. Soit $x^{[2]}$, le champ des étiquettes associé à cette segmentation. $\forall s \in S'$, $X_s^{[2]}$ prend ses valeurs dans $\{e_1 = \text{réverbération de fond}, e_2 = \text{écho}\}$. Cette segmentation utilise le champ d'observation $y^{[1]}$ constitué par l'ensemble des luminances des pixels étiquetés *réverbération* après la phase de segmentation en deux classes, $y^{[1]} = \{y_s, s \in S'\}$. La distribution de $(X^{[2]}, Y^{[1]})$ est définie par $P_{X^{[2]}/X^{[1]}}(x^{[2]}/\hat{x}^{[1]})$, la distribution *a priori* de $X^{[2]}$ supposée être markovienne et stationnaire, et par les fonctions de vraisemblance $P_{Y_s^{[1]}/X_s^{[2]}}(y_s^{[1]}/x_s^{[2]})$, $\forall s \in S'$. On cherche maintenant le champ d'étiquette $x^{[2]}$ tel que :

$$\hat{x}^{[2]} = \arg \max_{x^{[2]}} P_{X^{[2]}/X^{[1]}, Y^{[1]}}(x^{[2]}/\hat{x}^{[1]}, y^{[1]}) \quad (4.1)$$

En appliquant la règle de Bayes et après élimination de $P_{Y^{[1]}/X^{[1]}}(y^{[1]}/\hat{x}^{[1]})$ qui ne dépend pas de $x^{[2]}$, la relation précédente permet d'écrire :

$$\hat{x}^{[2]} = \arg \max_{x^{[2]}} P_{X^{[2]}, Y^{[1]}/X^{[1]}}(x^{[2]}, y^{[1]}/\hat{x}^{[1]}) \quad (4.2)$$

$$= \arg \max_{x^{[2]}} P_{Y^{[1]}/X^{[1]}, X^{[2]}}(y^{[1]}/\hat{x}^{[1]}, x^{[2]}) \cdot P_{X^{[2]}/X^{[1]}}(x^{[2]}/\hat{x}^{[1]}) \quad (4.3)$$

En vertu du théorème d'Hammersley et Clifford, $P_{X^{[2]}/X^{[1]}}(x^{[2]}/\hat{x}^{[1]})$ est définie comme étant une distribution de Gibbs :

$$P_{X^{[2]}/X^{[1]}}(x^{[2]}/\hat{x}^{[1]}) \triangleq \frac{1}{Z} \exp \left(-U_2(x^{[2]}, \hat{x}^{[1]}) \right) \quad (4.4)$$

avec $U_2(x^{[2]}, \hat{x}^{[1]})$, la fonction d'énergie du modèle *a priori* et Z une constante de normalisation. En posant $P_{Y^{[1]}/X^{[2]}, X^{[1]}}(y^{[1]}/x^{[2]}, \hat{x}^{[1]}) = \frac{1}{Z'} \exp(-U_1(y^{[1]}, x^{[2]}, \hat{x}^{[1]}))$, la relation (4.2) peut s'exprimer sous la forme d'une fonction d'énergie à minimiser :

$$\hat{x}^{[2]} = \arg \min_{x^{[2]}} \left\{ U_1(y^{[1]}, x^{[2]}, \hat{x}^{[1]}) + U_2(x^{[2]}, \hat{x}^{[1]}) \right\} \quad (4.5)$$

où $U_1(y^{[1]}, x^{[2]}, \hat{x}^{[1]})$ exprime l'adéquation entre les observations et les étiquettes $\{e_1, e_2\}$ et U_2 est le terme d'énergie correspondant au modèle *a priori*.

- le terme $U_1(y^{[1]}, x^{[2]}, \hat{x}^{[1]})$ résulte de la modélisation du lien entre les étiquettes et les observations. Pour la segmentation deux classes, nous avons utilisé une loi de Weibull $\mathcal{W}(y; \Phi_y)$ pour décrire la distribution de la luminance dans les zones de réverbération (cf. partie I). Du fait du très faible nombre de pixels appartenant à la classe *écho*, on peut approcher la distribution des niveaux de gris dans les régions *réverbération de fond* par cette même loi. On définit donc :

$$P_{Y_s^{[1]}/X_s^{[2]}}(y_s^{[1]}/e_1) = \frac{C}{\alpha} \left(\frac{(y_s - \min)}{\alpha} \right)^{C-1} \cdot \exp\left(-\frac{(y_s - \min)^C}{\alpha^C}\right) \quad (4.6)$$

avec $y > \min$, $\alpha > 0$, $C > 0$. $\Phi_y = (\min, C, \alpha)$ est estimé par la procédure ECI décrite en partie I. Nous ne connaissons pas la loi qui modélise le lien entre l'écho et sa représentation en niveau de gris et le faible nombre de pixels associés à cette classe ne nous permet pas de deviner sa nature. Néanmoins, on peut penser qu'un pixel doit avoir d'autant plus de chance d'être étiqueté *écho* que son niveau de gris associé est élevé. Nous proposons de modéliser empiriquement la distribution des niveaux de gris situés dans les régions *écho* par la loi suivante :

$$P_{Y_s^{[1]}/X_s^{[2]}}(y_s^{[1]}/e_2) = \frac{2}{\gamma} \Lambda_\gamma(y_s - y_{max}) \mathcal{U}(y_{max} - y_s) \quad (4.7)$$

avec $\mathcal{U}(\cdot)$ la fonction d'Heaviside, $\Lambda(\cdot)$ représente la fonction triangulaire, y_{max} le niveau de gris maximal présent dans l'image, et $(2/\gamma)$ une constante de normalisation. La figure 4.2 montre le tracé de cette loi pour $y_{max} = 255$.




FIG. 4.2 – Loi empirique utilisée pour modéliser la fonction d'intensité de classe *écho*.

Sous ces conditions, le terme d'énergie d'attache aux données $U_1(x^{[2]}, y^{[1]}, \hat{x}^{[1]})$ peut s'écrire :

$$U_1(x^{[2]}, y^{[1]}, \hat{x}^{[1]}) = - \sum_{s \in S'} \ln P_{Y_s^{[1]}/X_s^{[2]}}(y_s^{[1]}/x_s^{[2]}) \quad (4.8)$$

• Considérons maintenant $U_2(x^{[2]}, \hat{x}^{[1]})$, le terme d'énergie du modèle *a priori*. Nous adoptons un voisinage spatial du second ordre dans lequel β_1 , β_2 , β_3 , β_4 représentent les paramètres *a priori* associés aux cliques binaires horizontales, verticales, diagonales droite et gauche respectivement, et β_0 représente le paramètre de la clique unaire (cf. figure 4.3).

Ce terme d'énergie permet d'exprimer des contraintes sur la solution $x^{[2]}$. Dans notre application, nous privilégions les partitions en régions spatialement homogènes. À cette fin, nous utilisons un modèle de Potts anisotrope qui associe aux cliques binaires $\langle s, t \rangle$, des potentiels d'interactions de la forme :

$$V_{21}(x^{[2]}, \hat{x}^{[1]}) = \beta(1 - \delta(x_s^{[2]}, x_t^{[2]})) \quad (4.9)$$




FIG. 4.3 – Cliques à un et deux éléments pour le système de voisinage du second ordre et paramètres des potentiels associés.

où $\beta = \beta_1 = \beta_2 = \beta_3 = \beta_4$. Le potentiel de la clique singleton de paramètre β_0 permet de défavoriser l'affectation de l'étiquette *écho* aux sites éloignés d'une zone d'ombre. Pour définir ce potentiel, nous introduisons un champ de potentiel $\Psi_{\hat{x}^{[1]}}(t)$, ($t \in S'$) dans lequel chaque site s_0 , étiqueté *ombre* dans $\hat{x}^{[1]}$, crée le champ de potentiel élémentaire $\psi_{s_0}(r)$ défini par :

$$\forall t \in S', \quad \psi_{s_0}(r) = \frac{1}{r} \exp\left(-\frac{r}{\sigma}\right) \quad (4.10)$$

où r ($r \neq 0$) est la distance au pixel s_0 et σ est le paramètre contrôlant la distance d'interaction entre les régions écho et ombre. La figure 4.4 montre un exemple d'un tel champ de potentiel élémentaire. L'ensemble des pixels étiquetés *ombre* dans $\hat{x}^{[1]}$ crée un champ de potentiel global $\Psi_{\hat{x}^{[1]}}(t)$ résultant de la somme des différents champs de potentiel élémentaires $\psi_{s_0}(r)$:

$$\forall t \in S', \quad \Psi_{\hat{x}^{[1]}}(t) = \inf \left\{ \sum_{s \in S: \hat{x}_s^{[1]} = e_0} \psi_s(d(s, t)), 1 \right\} \quad (4.11)$$




FIG. 4.4 – Potentiel élémentaire créé par un pixel d'ombre.

où $d(s, t)$ représente la distance entre les pixels s et t . Le potentiel de la clique unaire, de paramètre β_0 , vise à défavoriser l'affectation de l'étiquette *écho* aux sites éloignés d'une zone d'ombre. La forme de ce potentiel est donnée par :

$$V_{22}(x^{[2]}, \hat{x}^{[1]}) = -\beta_0 \ln \Psi_{\hat{x}^{[1]}}(s) \delta(x_s^{[2]}, e_2) \quad (4.12)$$

Concrètement, l'action de ce potentiel sera de délimiter une région autour de laquelle l'étiquette *écho* ne sera pas défavorisée. La largeur de la zone créée peut être contrôlée par le paramètre σ de la relation (4.10). Hors de cette région, l'affectation à la classe "écho" sera d'autant plus défavorisé que le site à étiqueté se trouve loin d'une zone d'ombre et que cette zone d'ombre est petite. Nous avons représenté à la figure 4.5 une image SONAR segmentée en deux classes et le champ de potentiel associé pour différentes valeurs de σ .




FIG. 4.5 – *Champ de potentiel associé à une image SONAR segmentée. (a) Image SONAR réelle, (b) Image segmentée en deux classes (ombre/réverbération), (c) Champ de potentiel avec $\sigma = 2$, (d) Champ de potentiel avec $\sigma = 4$.*

Finalement, la fonction d'énergie globale à minimiser s'écrit :

$$\begin{aligned}
 U(x^{[2]}, \hat{x}^{[1]}, y^{[1]}) = & \underbrace{- \sum_{s \in S'} \ln P_{Y_s^{[1]}/X_s^{[2]}}(y_s^{[1]}/x_s^{[2]})}_{U_1(y^{[1]}, x^{[2]}, \hat{x}^{[1]})} + \underbrace{\sum_{\langle s, t \rangle \subset S'} \beta \left(1 - \delta(x_s^{[2]}, x_t^{[2]}) \right)}_{U_{21}(x^{[2]}, \hat{x}^{[1]})} \\
 & + \underbrace{\sum_{s \in S'} -\beta_0 \ln \Psi_{\hat{x}^{[1]}}(s) \delta(x_s^{[2]}, e_2)}_{U_{22}(x^{[2]}, \hat{x}^{[1]})}
 \end{aligned}$$

Nous avons recours à l'algorithme de relaxation déterministe ICM pour minimiser cette fonction d'énergie. Pour l'initialisation de cet algorithme, nous exploitons le résultat obtenu par une segmentation au sens du MV.

4.4 Résultats expérimentaux

Pour cette étape de segmentation en trois classes, nous utilisons les valeurs de paramètres suivantes : $\beta = \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_0 = 1$ pour les paramètres associés aux cliques binaires et unaire, et $\sigma = 2$ pour le paramètre contrôlant la distance d'interaction entre les régions *écho* et *ombre* (cf. équation (4.10)).

La planche 4.6 contient différentes segmentations en trois classes sur une image SONAR réelle représentant l'ombre portée d'un objet et d'un rocher. Plus précisément, cette planche illustre les résultats obtenus par une segmentation de la zone réverbérée, 1) au sens du MV, 2) avec le modèle markovien proposé sans information *a priori* sur la dépendance spatiale existante entre les régions ombre et écho (i.e., en posant $\beta_5 = 0$), et enfin, 3) avec le modèle markovien proposé incluant une information *a priori* sur la dépendance spatiale existante entre les régions ombre et écho. Le résultat obtenu par une estimation au sens du MV conduit à une segmentation partielle et bruitée (cf. figure 4.6.b). La prise en compte du terme d'énergie *a priori* permet de contraindre la cohérence spatiale de l'image et permet de privilégier les partitions en régions spatialement homogènes. Néanmoins, sans le terme d'énergie *a priori* exprimant la dépendance spatiale entre les zones classées *ombre* et *écho*, la méthode de segmentation ne permet pas totalement d'éliminer l'effet du bruit de speckle, ce qui crée des fausses zones d'écho (cf. figure 4.6.c) tout autour de l'ombre portée du rocher et de l'objet manufacturé. La méthode que nous proposons conduit à de meilleurs résultats et permet de ne considérer comme écho que les régions spatialement homogènes, de niveaux de gris élevés et situées à proximité d'une zone d'ombre.

Les planches 4.7 et 4.8 montrent respectivement les résultats d'une segmentation en trois classes obtenus sur des images SONAR synthétiques et réelles. Les figures 4.7.b et 4.7.e présentent des images SONAR synthétiques simulant l'ombre portée et l'écho créés respectivement par une sphère et un anneau métallique¹ sur un fond marin sablonneux, ainsi que les résultats obtenus par notre méthode de segmentation. Ces résultats que l'on peut comparer aux vérités terrain (cf. figure 4.7.a et 4.7.c) montrent que les segmentations obtenues sont proches des résultats espérés. Les résultats sur des images SONAR réelles sont présentés à la figure 4.8. Dans les exemples présentés, l'écho est quelquefois présent et caractéristique (cf. figures 4.8.c, 4.8.e, 4.8.g et 4.8.i) et quelquefois inexistant (cf. figures 4.8.a, et 4.8.k). Dans tous les cas testés, la segmentation obtenue est bonne et rapide ($\approx$ dix secondes sur station IBM P200 120Mhz pour une image de taille 256×256 pixels et pour la segmentation de la zone réverbérée). Les fausses zones d'ombre et d'écho créées par l'aspect granulaire du bruit de speckle ont été correctement éliminées, et les contours des régions étiquetées ombre ont été préservés.

4.5 Conclusion

Dans ce chapitre, nous avons proposé une démarche originale pour segmenter une image SONAR en trois classes (*ombre/réverbération de fond/écho*). Cette méthode tient compte du nombre peu élevé de pixels associés à la classe *écho*, tout en mettant à profit les bons résultats obtenus dans un premier temps par la segmentation SCM non supervisée en deux classes (*ombre/réverbération*). Le modèle utilisé tient compte de la vraisemblance des observations et intègre des informations *a priori* à différents niveaux de représentation (au niveau pixel et région). Les tests sur images synthétiques et réelles confirment l'intérêt de cette approche, et attestent la validité et la robustesse de la méthode proposée.

1. obtenu synthétiquement par une méthode de lancé de rayon.




FIG. 4.6 – Segmentation en trois classes d’une image SONAR réelle représentant l’ombre portée d’un objet et d’un rocher. (a) Image SONAR réelle, (b) Segmentation de la zone réverbérée au sens du MV. (c) Segmentation de la zone réverbérée avec le modèle markovien proposé sans information a priori sur la dépendance spatiale entre les régions écho et ombre ($\beta_0 = 0$). (d) Segmentation de la zone réverbérée avec le modèle markovien proposé incluant une information a priori sur la dépendance spatiale entre les régions écho et ombre ($\beta_0 = 1$).




FIG. 4.7 – Segmentations en trois classes d'images SONAR synthétiques. (a)(d) Ombre portée et écho créés par une sphère et un anneau métallique, obtenus synthétiquement par une procédure de lancé de rayon. (b)(e) Images SONAR synthétiques, avec ajout de bruit de speckle synthétique, simulant l'écho et l'ombre portée créée par une sphère et un anneau métallique posés sur un fond marin sablonneux. (c)(f) Résultats des segmentations en trois classes obtenus par notre méthode.




FIG. 4.8 – *Segmentation en trois classes sur images SONAR réelles. (a)(c)(e)(g)(i)(k) Images SONAR réelles. (b)(d)(f)(h)(j)(l) Images SONAR segmentées en trois classes (ombre/réverbération de fond/écho).*

Chapitre 5

Segmentation d'images SONAR de grande taille

La segmentation non supervisée que nous avons proposée suppose implicitement qu'il existe un seul type de fond marin dans l'image. Cette hypothèse n'est malheureusement pas toujours vérifiée pour certaines images SONAR de grande taille. Ces dernières peuvent présenter plusieurs fonds de nature différente ; rides de sable puis fond sablonneux par exemple. L'hypothèse selon laquelle les pixels de l'image associés aux zones d'ombre et aux zones de réverbération se répartissent selon deux lois d'attache aux données n'est dans ce cas plus vérifiée. Pour estimer des paramètres associés au modèle du bruit qui soient corrects, et ainsi extraire une segmentation adéquate, nous devons prendre en compte cette éventualité.

5.1 Segmentation d'images SONAR de grande taille

La segmentation automatique d'une image SONAR telle que nous l'avons proposée comprend trois étapes que nous rappelons :

- Une étape d'estimation des paramètres dans laquelle les paramètres du modèle de bruit et du modèle *a priori* sont estimés conjointement grâce à l'algorithme ECIG. Cette procédure est initialisée par l'algorithme des *K*-moyennes. Il permet d'estimer ces paramètres au sens du Maximum de Vraisemblance pour le modèle du bruit, et au sens des moindres carrés pour le modèle *a priori*.
- Une étape de segmentation en deux classes (*ombre/réverbération*) dans laquelle le champ d'étiquettes est estimé au sens du Maximum A Posteriori.
- Une étape de segmentation de la zone réverbération en deux classes *réverbération de fond/écho*.

Nous présentons à la figure 5.1 le synoptique complet de cet algorithme. L'algorithme proposé est non supervisé, et l'estimation des paramètres du modèle de bruit et du modèle *a priori* se fait automatiquement. Néanmoins, tel qu'il est proposé, l'algorithme a besoin de deux informations *a priori*.

1— La première est relative à la nature des lois associées aux différentes classes d'une image SONAR. Dans une modélisation "Gauss-Rayleigh", on suppose implicitement que la loi de répartition des niveaux de gris associée à la classe *ombre* est une loi normale et que celle associée à la classe *fond* est une loi de Rayleigh. Dans le cas d'une modélisation "Weibull-Weibull", cette information *a priori* sur la nature des lois associées au mélange de distributions est moins restrictive. De par sa grande flexibilité et pour certaines valeurs des paramètres, cette loi permet de modéliser une grande variété de distributions.

2— Une seconde information *a priori* importante que nous avons prise en compte est de supposer qu'il existe un seul type de fond marin dans l'image.

Cet *a priori* est malheureusement trop restrictif lorsqu'on traite une image SONAR de très grande taille, comme par exemple une image de taille 2500×2500 pixels correspondant à une bande de 250 mètres de longueur et de largeur. Ces images peuvent inclure plusieurs fonds marins différents, rides de sables, dunes, roches, fond sablonneux, etc. Pour certains types de fond, les dimensions des rugosités du sol marin peuvent être du même ordre de grandeur que les dimensions de la cellule de résolution. C'est le cas notamment des rides de sable grossier pour lesquelles la taille des grains constituant la texture du fond devient du même ordre de grandeur que la longueur d'onde du signal émis par le SONAR. Pour d'autres types de fond, notamment pour ceux constitués de zones homogènes comme les fonds vaseux ou sablonneux, la dimension de la cellule de résolution peut être supérieure aux dimensions des rugosités du fond marin. Dans certains cas aussi, des phénomènes d'interférences peuvent être liés à la présence de particules en suspension dans le volume d'eau, en particulier dans les zones peu profondes soumises à des mouvements importants de masse d'eau (marée, embouchure de fleuve, ...). Selon la nature macroscopique du fond réverbérant, la présence ou non de particules en suspension dans le volume d'eau, et la profondeur du fond marin, la nature de la loi de répartition des niveaux de gris associés à la classe *réverbération* peut être très différente.

Nous présentons à la figure 5.2 une image SONAR de grande taille (768×512 pixels). Cette image SONAR contient deux types de fond marin. Un fond sablonneux dans sa partie gauche et un autre constitué de dunes de sable dans sa partie droite. L'histogramme de cette image est fourni à la figure 5.3. Il montre clairement trois lois associées à trois classes dans l'image, et notamment deux lois différentes associées à deux types de réverbération du signal acoustique. Une loi associée aux zones d'ombre et aux zones de réverbération créées par la dune de sable (partie droite de l'image), et une loi associée à la réverbération du signal acoustique sur le fond sablonneux (partie gauche de l'image). Nous avons reporté les paramètres calculés sur des petites imagerie par l'algorithme des *K*-moyennes (cf. partie I) dans l'espace des représentations. Dans cet exemple, il est difficile aussi de trouver clairement deux groupements distincts associés aux classes *ombre* et *réverbération*.




FIG. 5.1 – *Synoptique de la chaîne de segmentation automatique d'une image SONAR.*




FIG. 5.2 – Image SONAR réelle présentant deux types de fond ; fond sablonneux puis dunes de sable.




FIG. 5.3 – (a) Histogramme de l'image SONAR présentée à la figure 5.2, (b) Nuage de points (créé par l'algorithme des K -moyennes) associés à l'image SONAR de la figure 5.2.

Pour résoudre ce problème, une solution simple, que nous avons adoptée, consiste à découper l'image en images plus petites, assez petites pour qu'un seul type de fond marin soit présent dans l'image, segmenter ensuite ces images, puis reconstituer l'image segmentée. Pour notre application, nous découpons l'image en "imagettes" de taille 512×512 pixels. Nous donnons à la figure 5.4 la segmentation obtenue par cette technique sur l'image SONAR de la figure 5.2.

5.2 Conclusion

Le découpage des grandes images en imagettes plus petites, puis la reconstitution de l'image segmentée permet à l'algorithme de traiter une image SONAR sur laquelle il n'existe qu'un seul type de fond marin et d'estimer efficacement les paramètres du modèle de bruit associés aux classes *ombre* et *réverbération*. D'autre part, cette méthode permet de compenser dans une certaine mesure le dysfonctionnement de la commande automatique de gain du SONAR.




FIG. 5.4 – *Résultat de la segmentation de l'image SONAR comportant deux types de fond de la figure 5.2.*

Conclusion

Dans cette partie, nous avons présenté et testé les algorithmes classiques mono-échelles de segmentation existants. Nous avons vu que les méthodes existantes telles que l'ICM ou le RS étaient soit rapides mais sous optimales, soit relativement efficaces mais aussi coûteuses en temps de calcul.

Nous nous sommes ensuite intéressés aux techniques plus récentes qui associent une représentation statistique de l'image et une hiérarchisation de l'information. Nous avons conclu que les méthodes appelées multigrille, multirésolution, multiéchelle selon la technique utilisée permettaient d'obtenir des améliorations sur la qualité de l'estimation et la rapidité de la méthode, d'autant plus importantes que la fonction d'énergie que l'on cherche à minimiser est complexe. La complexité calculatoire est beaucoup moins importante que pour une relaxation stochastique et les estimés sont dans tous les cas de meilleure qualité. Nous avons constaté que la présence de cliques inter-niveaux, notamment dans la méthode du SMAP proposée par Bouman *et al.* permettait aussi de réduire de façon significative l'effet du bruit de speckle présent de façon importante sur certaines images, mais que le système de voisinage trop simple utilisé, ne permettait pas de modéliser de façon précise toutes les propriétés locales et globales du champ d'étiquettes.

Nous avons alors proposé un modèle hiérarchique adapté à notre application et associé à un système de voisinage spatial, causal en échelle et une stratégie de minimisation multigrille. Le modèle global que nous avons appelé MCE (Multigrille Causal en Échelle) ou SCM (Scale Causal Multigrid) portant sur tous les niveaux de résolution de la pyramide des étiquettes, s'est avéré particulièrement efficace pour la segmentation d'images SONAR notamment celle présentant un bruit de speckle important. L'estimation des paramètres de ce modèle peut être réalisée efficacement, et sans augmenter de façon trop importante le temps de calcul, par une généralisation de l'estimateur de Derin *et al.*

Nous avons ensuite proposé une démarche originale pour segmenter une image SONAR en trois classes (*ombre/réverbération de fond/écho*). Cette méthode tient compte du nombre peu élevé de pixels associés à la classe *écho* et permet de tirer profit des résultats obtenus par une première segmentation SCM non supervisée en deux classes (*ombre/réverbération*). Le modèle utilisé associe à la vraisemblance des observations et des informations *a priori* à différents niveaux de représentation, au niveau pixel et région. Les tests sur des images SONAR synthétiques et réelles confirment l'intérêt des techniques proposées.

Troisième partie

Classification des ombres portées

Introduction

L'objectif de la classification en imagerie SONAR est, dans un premier temps, de pouvoir différencier les objets naturels des objets manufacturés comme l'épave d'un bateau, un pipe-line, etc. Une autre application d'une telle classification automatique est la lutte contre les mines. En effet, les objets reposant sur le fond peuvent représenter une menace éventuelle pour les navires. Il faut donc être en mesure de lever le doute sur leur nature afin d'éviter la mise en œuvre systématique de moyens lourds de destruction.

L'approche originale, que nous décrivons dans cette partie, repose sur la définition d'un modèle statistique représentatif des ombres portées associées à la classe d'objets que l'on cherche à détecter. Elle comprend la définition d'une forme prototype à laquelle sont appliquées des déformations géométriques linéaires. Notre méthode s'appuie sur la théorie bayésienne de la décision et utilise des caractéristiques extraites de l'image SONAR préalablement segmentée en deux classes (*ombre/réverbération*) ainsi que des techniques d'optimisation pour l'estimation des déformations de ce modèle. Nous verrons que le cadre de modélisation retenu et les solutions algorithmiques présentées dans cette partie sont suffisamment généraux pour s'appliquer à une large classe de modèles statistiques.

Cette partie est organisée de la façon suivante. Le chapitre 1 décrit le modèle statistique et la méthode bayésienne de détection retenue. Dans ce cadre, notre problème de détection d'une classe d'objets est équivalent à un problème d'estimation. Différentes techniques d'optimisation, stochastiques et déterministes, adaptées à notre problème d'estimation, sont décrites et testées dans le chapitre 2. Ce dernier chapitre est illustré de nombreux résultats expérimentaux qui attestent la pertinence de l'approche proposée.

Chapitre 1

Classification par modèle statistique

1.1 Introduction

En imagerie SONAR, l'identification des objets posés sur le fond marin est réalisée grâce à une analyse de la forme de l'ombre qu'ils produisent dans l'image SONAR.

Une solution simple, proposée jusqu'à présent, consiste à extraire chaque ombre portée par une première étape de segmentation en deux classes (*ombre/réverbération*), à calculer ensuite des attributs pertinents permettant de caractériser la forme de l'ombre (attributs statistiques, géométriques, liés à la répartition spectrale de l'ombre, descripteurs de Fourier, etc.), et enfin à utiliser ces informations comme entrée d'un classifieur quelconque (K plus proches voisins, classifieur bayésien, PMC, etc.) de manière à trouver les différentes classes recherchées [32, 34, 48]. Cette solution est classique en reconnaissance des formes, simple à implanter et bien adaptée à certains types de problèmes. Néanmoins, cette technique de classification reste largement dépendante de l'étape cruciale d'extraction des caractéristiques alors même qu'il n'existe pas de règles générales pour déterminer le nombre et la nature des attributs. Cette approche nécessite aussi une grande base de données pour l'apprentissage de l'algorithme de classification. Dans notre application, de telles données ne sont pas disponibles. De plus, l'ombre portée, que l'on cherche à classer, peut être occultée par l'ombre portée créée par des cailloux, d'une dune ou des rides de sable. Dans ce cas, les attributs statistiques de l'ombre portée s'en trouvent altérés et le classifieur risque de se tromper.

Contrairement à cette approche qui consiste à extraire de l'image segmentée chaque ombre portée et à identifier ensuite l'objet qui lui est associé, nous allons modéliser explicitement la forme de l'ombre portée associée à la classe d'objets considérée à l'aide d'un modèle déformable¹, et rechercher si cette forme prototype se trouve dans l'image segmentée. Ce modèle de forme sera associé à un ensemble de déformations limitées à des transformations linéaires admissibles.

Nous évoquerons dans ce chapitre les principes généraux de la méthode statistique de classification proposée. Elle repose sur une formulation bayésienne du problème, intégrant une fonction objective ϵ mesurant l'adéquation entre le modèle défini *a priori* et une zone donnée de l'image.

1.2 Représentation de la forme prototype

Contrairement à un objet naturel, un objet créé par l'homme est en général constitué d'un assemblage d'éléments de formes géométriques simples. Ces objets se traduisent dans l'image SONAR par la présence d'ombres (cf. figure 1.1) dont les contours sont constitués de segments de droite. C'est le cas notamment d'une épave de bateau (cf. figure 1.1.a), d'une mine cylindrique et de son chariot porteur (cf. figure 1.1.b), ou d'oléoducs (cf. figure 1.1.c). Pour un objet de forme géométrique simple, comme une mine cylindrique, l'ombre

1. D'abord utilisés en segmentation d'image [64, 59], ces modèles [42] sont maintenant exploités pour le suivi de structures déformables dans une séquence d'images [58, 82], et depuis peu pour la localisation d'objets [49] et la classification [52].

portée correspond à un parallélogramme théoriquement parfait (cf. figure 1.1.d). Pour un objet sphérique, mine sphérique par exemple, l'ombre portée reste très caractéristique et se traduit par une ellipse (cf. figure 1.2). Contrairement aux objets manufacturés, les rochers ou les cailloux créent des ombres chahutées aux formes aléatoires.




FIG. 1.1 – Ombre portée de différents objets manufacturés. (a) Épave de bateau. (b) Mine et son chariot porteur. (c) Oléoducs. (d) Mine cylindrique.

L'approche proposée requiert la définition d'une forme prototype 2D, représentant l'ombre portée générique de la classe d'objets à détecter. Cette forme γ_0 est définie par une suite de n points caractéristiques de son contour, joints par une courbe continue :

$$\gamma_0 = (x_1, y_1, x_2, y_2, \dots, x_n, y_n)^t \quad (1.1)$$

$\mathbf{x}_i = (x_i, y_i)^t$ désigne les coordonnées d'un point dans le plan et t le vecteur transposé. Les n points caractéristiques sélectionnés sont généralement associés aux lieux de forte courbure, identifiés sur le contour de l'objet étudié.

Dans le cas de la détection des mines ou des objets manufacturés de forme géométrique simple, l'ombre portée peut être assez bien approchée par un parallélogramme. Dans ce cas, γ_0 est définie par les quatre sommets du parallélogramme. Dans le cas de la détection de mines sphériques, l'ombre prototype est représentée par la suite de n points pris sur le contour de l'ombre acoustique. L'ombre portée associée à un objet sphérique peut être extraite d'une image réelle ou être simulée facilement par une technique de synthèse d'image comme le "lancé de rayon". La figure 1.2 représente l'ombre synthétique créée par un objet sphérique. Une représentation continue de la silhouette de cette forme est obtenue par une interpolation B-spline cubique du modèle échantillonné.




FIG. 1.2 – *Exemple synthétique (a) La région noire simule l'ombre portée créée par une sphère. Elle est obtenue par une méthode de lancé de rayon. (b) Une représentation continue de la silhouette de cette forme est extraite par une interpolation B-spline cubique du modèle échantillonné (dix points de contrôle pour cet exemple).*

1.3 Déformations associées

Nous associons à la structure prototype, définie précédemment, un ensemble de déformations limitées à des transformations linéaires, représentant l'ensemble des configurations admissibles issues de la forme prototype. Dans le cas du parallélogramme, ces déformations sont paramétrisées par : le facteur d'échelle s , la rotation d'angle α , l'élongation de paramètre h , le biais de facteur k et enfin la translation de vecteur t (cf. figure 1.3). Le modèle déformable est alors noté $\gamma_\theta = sA_\alpha A_k A_h \gamma_0 + t$ avec γ_0 un carré de côté un, centré à l'origine et avec $\theta = (s, \alpha, h, k, t)^t$ et $t = (t_x, t_y)^t$. La rotation d'angle α , l'élongation de facteur h , le biais de paramètre k définissent les matrices de transformation A_α , A_h , A_k :

$$A_\alpha = \begin{pmatrix} \cos\alpha & -\sin\alpha \\ \sin\alpha & \cos\alpha \end{pmatrix}$$

$$A_h = \begin{pmatrix} 1 & 0 \\ 0 & h \end{pmatrix}$$

$$A_k = \begin{pmatrix} 1 & k \\ 0 & 1 \end{pmatrix}$$

Ces transformations permettent de spécifier la position et les opérations géométriques appliquées à la forme prototype pour constituer l'ensemble des instances possibles. Ce modèle paramétrique est linéaire, et son degré de liberté est $m = 6$, correspondant au nombre de paramètres introduits.

Dans le cas d'un objet sphérique, l'ombre portée créée est symétrique par rapport à la direction d'émission de l'onde acoustique. Les seules transformations géométriques considérées incluent alors le facteur d'échelle, l'élongation et la translation, le nombre de degrés de liberté de ce modèle est $m = 4$ (cf. figure 1.4).

La loi *a priori* $P_{\Gamma_\Theta}(\gamma_\theta)$ caractérise le modèle probabiliste associé à γ_θ . Rappelons que θ est un vecteur de dimension m comprenant les différents paramètres des transformations linéaires considérées. Cette distribution ne dépend pas des données images, mais seulement des paramètres θ . Par la suite, nous noterons indifféremment cette loi $P_{\Gamma_\Theta}(\gamma_\theta)$ ou $P_\Theta(\theta)$ pour alléger les notations.




FIG. 1.3 – Ensemble des déformations considérées pour un modèle *a priori* associé à l'ombre portée d'un objet de forme cylindrique ou de forme géométrique simple. A ces transformations, il est nécessaire d'ajouter la translation en x (t_x) et la translation en y (t_y).




FIG. 1.4 – Ensemble des déformations considérées pour un modèle *a priori* associé à l'ombre portée d'un objet de forme sphérique. A ces transformations, il est nécessaire d'ajouter la translation en x (t_x) et la translation en y (t_y).

1.4 Détection de la classe d'objets considérée

La détection de la classe d'objets considérée est basée sur une fonction de coût ϵ évaluant la ressemblance entre le modèle défini *a priori*, pour une configuration donnée du modèle déformable, et la zone extraite de l'image.

Dans notre application, cette fonction n'est pas liée directement à l'image des intensités Y , mais à des caractéristiques extraites de la carte de segmentation en deux classes (*ombre/réverbération*). Plus précisément, la mesure que nous proposons exploite deux types d'informations complémentaires. La première concerne les contours des différentes ombres détectées ; elle est liée aux gradients spatiaux de la carte de segmentation x . La seconde est relative à l'homogénéité des différentes régions détectées. D'un point de vue probabiliste, $\epsilon(\theta, x)$ définit le modèle joint *via* la distribution de Gibbs suivante :

$$P_{\Theta, X}(\theta, x) = \frac{1}{Z} \exp\{-\epsilon(\theta, x)\} \quad (1.2)$$

où Θ est le vecteur de paramètres, Z une constante de normalization, et $\epsilon(\theta, x)$ la fonction d'énergie composée de deux termes comme indiquée ci-après :

1.4.1 Terme d'énergie ϵ_c liée aux contours des ombres

Soit x' , une version filtrée passe-haut et binarisée de l'image SONAR segmentée, c'est-à-dire l'image des contours des ombres détectées, et S' le sous-ensemble de pixels classés "contour d'ombre" dans x' . Le modèle déformable sera attiré par les contours d'une ombre donnée par l'intermédiaire d'un champ de potentiel défini de la façon suivante. Chaque pixel $s_0 \in S'$ de coordonnées (x_0, y_0) , classé "contour d'ombre", crée en $(x, y) \neq (x_0, y_0)$ le champ élémentaire suivant :

$$\phi_{s_0}(r) = \frac{1}{r} \exp\left(-\frac{r}{\sigma}\right) \quad (1.3)$$

où $\sigma > 0$, et $r = \sqrt{(x - x_0)^2 + (y - y_0)^2}$ est la distance séparant le pixel s_0 et le pixel de coordonnées (x, y) . Nous avons représenté graphiquement, à la figure 1.5, le potentiel ϕ_{s_0} ainsi créé. Dans cet exemple, $\sigma = 4$.




FIG. 1.5 – *Potentiel créé par un pixel classé contour d'ombre dans x' .*

L'ensemble des pixels classés “contour d'ombre” de l'image x' créent un champ global de potentiel $\Phi_{S'}(t)$ qui est la somme des différents champs élémentaires $\phi_{s_0}(r)$:

$$\Phi_{S'}(t) = \inf \left\{ \sum_{s \in S'} \phi_s(d(s, t)), 1 \right\} \quad \forall t \in S \quad (1.4)$$

où $d(s, t)$ note la distance entre les pixels s et t . Concrètement, ce champ de potentiel va induire une version lissée de l'image des contours x' , dans laquelle un site sera d'autant plus proche d'un contour que son potentiel est proche de un. L'importance du lissage est contrôlé par le paramètre σ de la relation (1.3). Nous avons représenté à la figure 1.6 une image SONAR, sa segmentation markovienne en deux classes *ombre/réverbération*, et le champ de potentiel $\Phi_{S'}$ associé ($\sigma = 1$ dans cet exemple).




FIG. 1.6 – *Champ global de potentiel extraits de l'image SONAR. (a) Image SONAR. (b) Image SONAR segmentée en deux classes ombre/réverbération. (c) Champ global de potentiel associé avec $\sigma = 1$.*

Une énergie d'interaction, liée aux contours de chaque ombre détectée, est définie entre le modèle déformable et le champ de potentiel $\Phi_{x'}(t)$ créé. Cette énergie vise à coller le modèle déformable aux contours d'une ombre. Cette énergie est minimale s'il existe une adéquation exacte entre le modèle déformable et le contour d'une ombre portée détectée préalablement extraite.

$$\epsilon_c(\theta, x) = -\ln \left\{ \frac{1}{N_{\gamma_\theta}} \sum_{s \in \gamma_\theta} \Phi_{S'}(s) \right\} \quad (1.5)$$

où N_{γ_θ} représente le nombre de pixels du modèle déformable γ_θ . La fonction logarithme est utilisée pour accroître la dynamique des valeurs prises par la fonction d'énergie ϵ_c .

1.4.2 Terme d'énergie ϵ_r liée aux régions d'ombre

Ce terme d'énergie d'interaction tend à positionner l'intérieur du modèle déformable dans une région classée *ombre* par l'étape de segmentation en deux classes. L'énergie d'interaction ϵ_r est minimale si les pixels situés à l'intérieur du modèle ont bien été étiquetés *ombre* à l'issue de l'étape de segmentation. Elle est donnée par :

$$\epsilon_r(\theta, x) = -\ln \left\{ \frac{1}{N_{\gamma_\theta^\bullet}} \sum_{s \in \gamma_\theta^\bullet} \delta(x_s, e_0) \right\} \quad (1.6)$$

où $\gamma_\theta^\bullet$ et $N_{\gamma_\theta^\bullet}$ désignent l'intérieur du modèle γ_θ et le nombre de pixels situés à l'intérieur de ce modèle. $\delta(.)$ est la fonction de Kronecker.

L'énergie totale ϵ est alors la somme de ces deux termes d'énergie :

$$\epsilon(\theta, x) = \epsilon_c(\theta, x) + \epsilon_r(\theta, x) \quad (1.7)$$

En résumé, la minimisation de cette énergie vise à placer le modèle déformable sur les contours d'une des ombres détectées et à regrouper à l'intérieur du modèle les pixels étiquetés *ombre*. La distribution *a posteriori* déduite de la relation (1.2) s'écrit donc comme suit :

$$P_{\Theta/X}(\theta/x) = \frac{1}{Z_x} \exp - \underbrace{\left\{ \epsilon_c(\theta, x) + \epsilon_r(\theta, x) \right\}}_{\epsilon(\theta, x)} \quad (1.8)$$

où Z_x est une constante de normalisation ne dépendant que de x .

1.4.3 Détection et classification d'une classe d'objets

L'estimation au sens du MAP des paramètres θ de la déformation appliquée au modèle de forme considéré peut s'écrire :

$$\hat{\theta}_{MAP} \in \arg \max_{\theta} \{ P_{\Theta/X}(\theta/x) \} \quad (1.9)$$

$$\in \arg \min_{\theta} \{ \epsilon(\theta, x) \} \quad (1.10)$$

Nous verrons dans le chapitre suivant que différentes techniques d'optimisation peuvent être mises en œuvre pour estimer θ .

L'estimation de θ permet de détecter ou d'extraire de l'image un objet, ou une zone d'intérêt, éventuellement partiellement occulté, ressemblant le plus, au sens du MAP, au modèle statistique défini *a priori*. La valeur finale de l'énergie d'interaction sera ensuite exploitée pour décider si l'objet sélectionné fait partie ou non de la classe d'objets considérée. Des résultats expérimentaux seront donnés dans le chapitre suivant et permettront d'attester l'intérêt de cette approche.

1.5 Conclusion

Nous avons présenté dans ce chapitre, un modèle original pour la détection et la classification statistique des ombres portées en imagerie SONAR. L'approche repose sur une formulation bayésienne du problème, intégrant la définition d'une forme prototype à laquelle sont appliquées des déformations linéaires et un modèle joint utilisant des informations extraites d'une segmentation préalable de l'image en deux classes *ombre/réverbération*. Ce modèle joint exploite des connaissances relatives aux contours et à l'homogénéité des régions détectées par cette procédure de segmentation. Dans ce contexte, le problème de l'identification d'une classe d'objet donnée est équivalent à un problème d'estimation bayésienne des paramètres de la déformation admissible du modèle. Cette estimation conduit à la minimisation d'une fonction d'énergie globale, non linéaire, qui fait l'objet du chapitre suivant.

Chapitre 2

Techniques d'optimisation

2.1 Introduction

Nous avons vu précédemment que le problème de l'identification d'une classe d'objets est formulé comme l'estimation bayésienne des paramètres θ de la déformation appliquée au modèle statistique défini *a priori*. Cette estimation de θ au sens du MAP conduit à la minimisation d'une fonction d'énergie globale, non linéaire, qui décrit les interactions entre le modèle déformable et l'image SONAR segmentée. La recherche de la solution minimisant cette fonction d'énergie est un problème difficile en raison de la dimension élevée de l'espace des configurations ainsi que de la présence de nombreux *minima* locaux. Pour le résoudre, on peut faire appel à deux grandes catégories d'algorithmes :

- les algorithmes *stochastiques* convergeant en un temps très long vers un minimum global de la fonction d'énergie, indépendamment de la configuration initiale.
- les algorithmes de relaxation *déterministes* atteignant au bout d'un nombre fini d'itérations un minimum local. Cette convergence vers un minimum local est raisonnable si l'initialisation de la procédure est proche de la solution désirée pour l'ICM ou pour une technique de descente du gradient.

Dans ce chapitre, nous comparons les résultats obtenus par trois techniques d'optimisation. La première est une procédure d'optimisation déterministe et repose sur une technique proche d'une descente de gradient. La seconde, le recuit simulé, est une procédure d'optimisation globale inspirée de l'étude de phénomènes physico-chimiques liés au refroidissement de systèmes cristallins jusqu'à leur point de stabilité maximale, c'est-à-dire d'énergie minimale; cette technique bien connue a été beaucoup utilisée dans des problèmes d'imagerie. La troisième est un algorithme génétique, procédure d'optimisation globale dont le principe s'inspire des mécanismes d'évolution des organismes vivants.

2.2 Descente de gradient

Une approche simple, proposée en [49], consiste à utiliser des algorithmes de minimisation usuels développés pour des applications très variées. L'algorithme de descente de gradient en est un exemple, et modifie l'estimation courante dans la direction opposée au gradient de la fonction à minimiser :

$$\theta^{k+1} = \theta^k - \alpha \frac{\partial \epsilon(\theta, x)}{\partial \theta} \quad (2.1)$$

Les limitations de cette technique ont été exposées précédemment : la solution estimée correspond à un minimum local de la fonction d'énergie $\epsilon(\theta, x)$ dépendant des observations x et d'un ensemble de paramètres cachés θ . Une initialisation proche de la solution optimale s'avère donc indispensable. La solution estimée

correspond enfin au minimum global si et seulement si la fonction d'énergie est convexe. Par ailleurs, une expression analytique du gradient de $\epsilon(\theta, x)$ par rapport à θ doit être disponible pour utiliser cet algorithme. Dans le cas qui nous intéresse, cette expression analytique n'existe pas. Par contre, on peut envisager de calculer numériquement cette expression pour chacune des directions θ_i , et proposer, par exemple, la procédure itérative suivante :

$$\theta^{k+1} = \theta^k - \text{sgn}\left(\frac{\partial \epsilon(\theta, x)}{\partial \theta}\right) \Delta\theta \quad (2.2)$$

où $\text{sgn}(x)$ représente le signe de x et $\Delta\theta$ le pas utilisé. Cette approche locale permet de converger très rapidement vers la solution optimale, sous la contrainte de disposer d'une estimation satisfaisante de la configuration initiale dans un domaine localement convexe. Dans notre cas, cette initialisation pourrait se faire manuellement mais cette option n'est pas compatible avec les besoins opérationnels. Une autre approche, également proposée en [49], consiste à échantillonner en θ la fonction d'énergie $\epsilon(\theta, x)$ et à utiliser les différents échantillons obtenus pour initialiser la procédure d'exploration locale de descente de gradient. On retient ensuite la solution associée à l'énergie la plus faible. D'une part, le pas d'échantillonnage ne doit pas être trop important sous peine d'avoir une configuration trop éloignée du minimum global ou séparée de celui-ci par une région non convexe, et d'obtenir une solution sous-optimale correspondant à un minimum local. D'autre part, ce pas d'échantillonnage ne doit pas être trop fin sous peine d'explosion combinatoire. L'optimisation de θ par la technique déterministe que nous proposons est résumée dans le tableau 2.1.

□ **Algorithme**

- | | |
|------------------|---|
| ϵ | Fonction d'énergie |
| θ | Vecteur de paramètres de la déformation |
| $\Delta\theta_i$ | Pas d'intégration de chaque paramètre |
- Échantillonnage en θ de la fonction $\epsilon(\theta, x)$.
 - Pour chaque configuration ou échantillon obtenu :
 - Pour chacun des paramètres θ_i ($1 < i < m$)
 - Évaluer :

$$\epsilon(\theta_1, \dots, \theta_i - \Delta\theta_i, \dots, \theta_m)$$

$$\epsilon(\theta_1, \dots, \theta_i, \dots, \theta_m)$$

$$\epsilon(\theta_1, \dots, \theta_i + \Delta\theta_i, \dots, \theta_m)$$
 - Retenir la configuration θ associée à l'énergie la plus faible.
 - On arrête la procédure pour cet échantillon lorsque l'énergie $\epsilon(\theta, x)$ est stable et on mémorise l'estimation obtenue si l'énergie trouvée est plus faible que la dernière meilleure estimation.

TAB. 2.1 – *Algorithme déterministe utilisé pour l'optimisation de θ .*

Nous avons rassemblé à la figure 2.1 différentes détections et classifications obtenues sur notre base d'images-test. On peut remarquer que pour les cas simples des figures 2.1.a et 2.1.b, les résultats obtenus par cette méthode sont corrects et conduisent à des estimations comparables aux procédures d'optimisation globale plus complexes présentées par la suite. Pour ces deux images, la configuration initiale fournie à la procédure de descente de gradient est suffisamment bonne et/ou la fonction $\epsilon(\theta, x)$ est "suffisamment convexe" pour que la solution estimée corresponde au minimum global. Par contre, dans des situations plus complexes, correspondant par exemple aux images des figures 2.1.c et 2.1.f, sur lesquelles figurent des ombres portées

de rochers et de mines avec présence d'occultations partielles, ou à l'image de la figure 2.1.e comportant des ombres portées d'objets manufacturés plus complexes qu'un simple cylindre, les résultats conduisent à une solution sous-optimale. De ce fait, la valeur de l'énergie finale résultant de cette procédure d'optimisation est difficilement exploitable dans le cadre d'une classification par modèle statistique.




FIG. 2.1 – **Détection/classification par modèle statistique et optimisation par descente de gradient.** Dans certains cas, la solution obtenue est quasi-optimale (a, b). Dans d'autres, la solution obtenue correspond à un minimum local inapproprié.

2.3 Recuit simulé

La technique du recuit simulé a été introduite pour le traitement de problèmes d'optimisation combinatoire de type placement de circuits ou voyageur de commerce. Cette procédure s'est révélée aussi très efficace pour résoudre des problèmes d'imagerie discrets comme la segmentation d'image ou récemment pour la détection et la segmentation au sens du mouvement [52, 58].

Dans le problème qui nous intéresse, les paramètres du modèle dont on recherche une instance dans l'image forment des processus aléatoires, notés respectivement Θ et X , dont la distribution jointe peut s'exprimer comme une distribution de Gibbs :

$$P_{\Theta, X}(\theta, x) \triangleq \frac{1}{Z_x} \exp\{-\epsilon(\theta, x)\} \quad (2.3)$$

$\epsilon(\theta, x)$ est la fonction que l'on cherche à minimiser. La recherche du minimum de cette fonction d'énergie est rendue possible par l'introduction d'une procédure d'échantillonnage de cette distribution couplée à un

schéma de refroidissement en température. Des techniques de Monte-Carlo permettent de simuler la nouvelle distribution de Gibbs paramétrée par un facteur de température T :

$$P_{[T]\Theta/X}(\theta/x) \triangleq \frac{1}{Z(T, x)} \exp\left\{-\frac{\epsilon(\theta, x)}{T}\right\} \quad (2.4)$$

Le schéma de refroidissement (i.e., une baisse de la température T) combiné à une technique d'échantillonnage simulant la distribution $P_{[T]\Theta/X}(\theta/x)$, a pour effet d'accuser progressivement le relief énergétique, et donc de concentrer la distribution de Gibbs (relation (2.4)) autour des modes principaux de $P_{\Theta/X}(\theta/x)$, lorsque la température chûte. L'identification du mode principal de la distribution, c'est-à-dire du minimum global de la fonction d'énergie $\epsilon(\theta, x)$, demeure l'objectif à atteindre *in fine*. L'algorithme du recuit simulé implique une décroissance de la température selon une loi logarithmique suffisamment lente afin de garantir la convergence vers l'optimum global [36]. On lui préfère généralement une loi de descente exponentielle, plus rapide, mais n'assurant pas obligatoirement la convergence vers le minimum global¹ :

$$T_{k+1} = aT_k \quad (2.5)$$

où $0 < a < 1$ est une constante proche de 1. Par ailleurs, la température initiale T_0 doit être suffisamment élevée pour que la distribution $P_{[T_0]\Theta/X}(\theta/x)$ soit proche de la distribution uniforme. L'optimisation de $\theta = (\theta_1, \theta_2, \dots, \theta_m)$ par la procédure du recuit simulé et l'échantillonneur de métropolis est résumée dans le tableau 2.2 :

□ **Algorithme** RECUIT SIMULÉ

T_0	Température initiale
a	Taux de refroidissement
θ	Vecteur de paramètres des déformations
θ^0	Configuration initiale des paramètres
ϵ	Fonction d'énergie

– $T \leftarrow T_0$

– $k \leftarrow 0$

• Initialisation aléatoire de θ^0 , $\theta \leftarrow \theta^0$.

• Tant que ($k < \text{seuil}$) répéter :

– Pour chacun des paramètres θ_i ($1 < i < m$) :

- Construire une configuration θ' ne différant de θ que sur l'élément θ_i .
- La configuration θ' est acceptée avec la probabilité P' :

$$P'(\theta') = \min\left\{\frac{\exp\left\{-\frac{\epsilon(\theta', x)}{T_k}\right\}}{\exp\left\{-\frac{\epsilon(\theta, x)}{T_k}\right\}}, 1\right\}$$

– Faire décroître la température : $T_{k+1} = aT_k$ et incrémenter l'itération $k = k + 1$.

TAB. 2.2 – Optimisation de θ par l'algorithme du recuit simulé.

1. Cette loi de descente exponentielle sera adoptée dans toutes nos expérimentations.

2.3.1 Résultats expérimentaux

L'indépendance de cette méthode d'optimisation globale vis à vis des conditions initiales est illustrée sur les figures 2.3, 2.4, 2.5 et 2.6. Des images SONAR réelles contenant des objets manufacturés de formes géométriques simples, montrées à la figure 2.5, avec des occultations partielles par des rochers ou des cailloux, ont été choisies afin de démontrer la validité de cette approche. Les figures 2.3, 2.4, 2.5 et 2.6 présentent chacune une image SONAR, l'image segmentée en deux classes (*ombre/réverbération*) exploitée dans le terme de vraisemblance conditionnelle des observations, et quelques étapes intermédiaires du recuit simulé. Le résultat final associé à l'estimation de θ est représentés aux figures 2.3.1, 2.4.1, 2.5.1 et 2.6.1. La figure 2.2 montre l'évolution des valeurs de la fonction d'énergie au cours des itérations du recuit simulé pour l'image SONAR de la figure 2.5. Dans nos expérimentations, nous avons adopté les paramètres suivants : $T_0 = 1$, T_f , (température finale) est fixé à 0.005 et $\alpha = 0.9997$.

Les résultats expérimentaux montrent que la zone détectée par notre méthode est l'ombre portée associée à l'objet manufacturé, quand celui-ci est bien sûr présent dans l'image SONAR. Dans ces cas, illustrées sur les figures 2.3, 2.4, 2.5, l'énergie faible obtenue ($\epsilon(\theta, x) < 0.2$) permet de classer cette ombre portée en " ombre portée d'objet manufacturé".

Quand aucun objet manufacturé n'est présent dans l'image, c'est le cas de l'exemple montré à la figure 2.6, l'énergie finale obtenue, de valeur élevée, indique une faible ressemblance entre les différentes formes prototypes définies *a priori* et la zone d'intérêt détectée sur l'image. L'algorithme permet alors de conclure qu'aucun objet manufacturé n'est présent dans l'image.




FIG. 2.2 – Évolution des valeurs de la fonction d'énergie au cours des itérations de l'algorithme de recuit simulé pour l'image SONAR de la figure 2.5.




FIG. 2.3 – **Détection/classification par modèle statistique et optimisation par recuit simulé.** (a) Segmentation en deux classes de l'image présentée en (b-l). Ombre portée d'une mine. (b) Initialisation du modèle. (c-k) Étapes intermédiaires de l'algorithme de recuit simulé avec respectivement, $T = 1$; $T = 0.74$; $T = 0.55$; $T = 0.40$; $T = 0.30$; $T = 0.22$; $T = 0.16$; $T = 0.12$; $T = 0.05$; $T = 0.03$; $T = 0.005$ (l) Détection finale. Cet exemple est facile car peu d'objets sont présents dans l'image, la région délimitée par le modèle statistique est bien l'ombre portée associée à la mine. La valeur d'énergie obtenue faible ($\epsilon = 0.15$) permet de classer cette ombre en "ombre de mine cylindrique ou d'objet manufacturé".




FIG. 2.4 – **Détection/classification par modèle statistique et optimisation par recuit simulé.** (a) Segmentation en deux classes de l'image présentée en (b-l). Ombre portée d'un rocher (en haut) et d'une mine (en bas). (b) Initialisation du modèle. (c-k) Étapes intermédiaires de l'algorithme de recuit simulé avec respectivement, $T = 1$; $T = 0.74$; $T = 0.55$; $T = 0.40$; $T = 0.30$; $T = 0.22$; $T = 0.16$; $T = 0.12$; $T = 0.05$; $T = 0.03$; $T = 0.005$. (l) Détection finale. La zone détectée par notre méthode est bien l'ombre portée associée à la mine. L'énergie finale obtenue faible ($\epsilon = 0.19$) permet de classer cette ombre en "ombre de mine cylindrique ou d'objet manufacturé".




FIG. 2.5 – **Détection/classification par modèle statistique et optimisation par recuit simulé.** (a) Segmentation en deux classes (ombre/réverbération) de l'image présentée en (b-l); Ombre de rochers et d'une mine cylindrique, avec des occultations partielles. (b) Initialisation du modèle. (c-k) Étapes intermédiaires de l'algorithme du recuit simulé avec respectivement, $T = 1$; $T = 0.74$; $T = 0.55$; $T = 0.40$; $T = 0.30$; $T = 0.22$; $T = 0.16$; $T = 0.12$; $T = 0.05$; $T = 0.03$; $T = 0.005$. (l) Détection finale. Le minimum global estimé par le recuit simulé est ensuite utilisé pour mesurer la "ressemblance" de notre modèle a priori avec la zone d'intérêt détectée sur cette image. Dans cet exemple, l'énergie finale obtenue faible par la procédure d'optimisation ($\epsilon = 0.13$) permet de classer sans ambiguïté l'ombre de cet objet en "ombre de mine cylindrique ou d'objet manufacturé".




FIG. 2.6 – **Détection/classification par modèle statistique et optimisation par recuit simulé.** (a) Segmentation en deux classes de l'image présentée en (b-l). Ombre de rochers. (b) Initialisation du modèle. (c-k) Étapes intermédiaires de l'algorithme du recuit simulé avec respectivement, $T = 1$; $T = 0.74$; $T = 0.55$; $T = 0.40$; $T = 0.30$; $T = 0.22$; $T = 0.16$; $T = 0.12$; $T = 0.05$; $T = 0.03$; $T = 0.005$. (l) Détection finale. Dans cet exemple, l'énergie finale obtenue de valeur élevée ($\epsilon = 0.48$) indique une faible "ressemblance" entre la forme prototype définie a priori et la zone d'intérêt détectée sur l'image. On doit essayer les autres formes prototypes possibles et en particulier celle associée à l'ombre portée de la mine sphérique pour classer l'ombre portée de cet objet comme étant celle d'un "objet naturel".

2.4 Algorithmes génétiques

Dans cette partie, nous présentons les principes généraux des algorithmes génétiques (AG) et les avantages que ces derniers possèdent sur des procédures d'optimisation plus classiques comme le recuit simulé. Le développement d'un AG pour l'optimisation globale de θ est décrit et des résultats d'estimation sur des images réelles sont montrés.

2.4.1 Principe

Les algorithmes génétiques [38] sont des algorithmes d'exploration qui peuvent servir à la recherche du minimum d'une fonction d'énergie. Ils sont fondés sur les mécanismes de la sélection naturelle et de la génétique. Ils mettent à profit à la fois les principes de survie des structures les mieux adaptées, et des échanges d'information pseudo-aléatoires entre individus. Il s'agit donc d'algorithmes d'exploration qui s'inspirent des mécanismes d'évolution des organismes vivants. A chaque génération, un nouvel ensemble de créatures artificielles, c'est-à-dire des chaînes de caractères, est créé en utilisant des parties des meilleurs éléments de la génération précédente ainsi que des parties innovatrices à l'occasion. Bien que reposant sur le hasard, les algorithmes génétiques ne sont pas des procédures d'exploration purement aléatoires. Ils exploitent efficacement l'information détenue pour spéculer sur la position de nouveaux points à explorer, avec l'espoir d'améliorer la performance [38].

Les algorithmes génétiques ont été développés par John Holland [38]. Depuis lors, un grand nombre d'articles et de thèses [38] ont établi l'intérêt de cette approche pour des applications d'optimisation de fonctions et d'exploration d'espaces complexes. Ayant été reconnus applicables à la résolution de problèmes nécessitant une exploration performante et économique en temps de calcul, les algorithmes génétiques sont maintenant étudiés dans un nombre grandissant d'applications. Ces algorithmes sont simples, performants et ne sont pas fondamentalement limités sur la continuité, l'existence de dérivées, l'unimodalité, de la fonction à optimiser.

Ces algorithmes procèdent de manière itérative à travers l'évolution d'une population de N individus de génération en génération. Chaque individu symbolise une solution de l'espace de recherche. Il est identifié par un chromosome $\underline{\theta} = (c_1, c_2, \dots, c_L)$, constitué d'une liste finie de L gènes c_i pouvant prendre des valeurs, ou allèles, dans un alphabet prédéfini [38]. Le choix se porte le plus souvent sur un alphabet binaire, $c_i = 1, 0$, plus commode pour assurer une convergence vers une solution appropriée en peu d'itérations. Une fonction d'évaluation, appelée aussi fonction de coût ou d'adaptation, constituant la fonction à optimiser, est attribuée à chaque chromosome. Elle permet d'évaluer sa "performance", c'est-à-dire l'adéquation du chromosome aux données. Cette fonction et la longueur de l'encodage sont les seules spécifications de l'utilisateur sur l'algorithme génétique. Les différentes étapes d'un tel algorithme peuvent se résumer de la manière suivante.

Reproduction: Les solutions jugées suffisamment performantes sont conservées d'une génération à l'autre, tandis que les moins performantes sont écartées. Plus précisément, chaque chaîne est copiée en fonction des valeurs de la fonction d'adaptation, ce qui revient à donner aux chaînes dont la valeur d'adaptation est la plus grande une probabilité plus élevée de contribuer à la génération suivante par la création d'au moins un descendant. Cet opérateur peut être vu comme une version artificielle de la sélection naturelle selon le schéma Darwinien de survie des individus les mieux adaptés. Dans les populations naturelles, l'adaptation est déterminée par la capacité d'une créature à survivre, aux prédateurs, aux maladies, ..., pour atteindre l'âge adulte et la période de reproduction. Dans un environnement artificiel, la fonction de coût est l'arbitre décidant de la vie ou de la mort de chaque chromosome ou chaîne de caractères sensée le représenter.

Une fois qu'une chaîne a été sélectionnée, une réplique exacte en est faite. Cette chaîne est alors ajoutée dans le groupe qui constitue l'ébauche de la nouvelle génération et qui est ensuite soumis à d'autres opérateurs génétiques. De cette façon, les chaînes bien adaptées ont un plus grand nombre de descendants dans les générations suivantes. Supposons qu'à l'itération k , la population de l'AG soit constituée de N chaînes, ou chromosomes, $\underline{\theta}_i^k$:

$$\text{POP}_k = \left\{ \underline{\theta}_1^k, \dots, \underline{\theta}_N^k \right\} \quad (2.6)$$

Appelons $\mathcal{F}$ la fonction d'évaluation ou d'adaptation. La chaîne $\underline{\theta}_i^k$ est sélectionnée pour la génération suivante avec la probabilité $p(\underline{\theta}_i^k)$:

$$p(\underline{\theta}_i^k) = \frac{\mathcal{F}(\underline{\theta}_i^k)}{\sum_{j=1}^N \mathcal{F}(\underline{\theta}_j^k)} \quad (2.7)$$

Croisement : L'étape d'évaluation est suivie d'une étape d'évolution régie par un processus qui s'opère en deux temps. Premièrement, les chaînes sont appariées au hasard par des tirages au sort, ce qui conduit à regrouper par paires les chromosomes. Deuxièmement, on croise les chaînes appariées par des tirages au sort (avec une loi uniforme) pour le choix des lieux de croisement (cf. figure 2.7).




FIG. 2.7 – Schéma du croisement simple illustrant l'alignement de deux chaînes et l'échange partiel d'informations avec un lieu de croisement choisi au hasard.

Mutation : La mutation joue un rôle secondaire dans la mise en œuvre des algorithmes génétiques. Cette étape d'évolution est cependant nécessaire car elle permet d'éviter la perte irréparable de matériel génétique partiellement important comme des 1 ou des 0 à des endroits précis, durant l'étape de croisement. Dans un AG, la mutation résulte d'une modification aléatoire occasionnelle, de faible probabilité P_{mut} , de la valeur d'un caractère de la chaîne. Pour un codage binaire, cela revient simplement à changer un 1 en 0 ou vice-versa. Prise isolément, la mutation constitue une exploration aléatoire de l'espace de recherche.

Recomposition : La procédure s'achève par une phase de "recomposition". La descendance est substituée à la population parentale dans le cas le plus simple. D'autres modes de recomposition favorisent "l'élitisme" [38] en préservant les individus les plus performants², ou le "recouvrement" où une fraction de la population seulement subit la sélection.

Fonction d'adaptation

Dans notre application, on peut facilement dériver une fonction d'adaptation $\mathcal{F}$, que l'on cherchera ici à maximiser, directement à partir de la fonction d'énergie globale ϵ introduite dans le chapitre précédent. Pour ce faire, et pour assurer à $\mathcal{F}$ des valeurs comprises dans l'intervalle $[0, 1]$, on considère l'expression suivante :

$$\mathcal{F}(\underline{\theta}_i) = \exp\{-\epsilon(\underline{\theta}_i, x)\} \quad (2.8)$$

2. Cette stratégie est aussi celle utilisée dans la suite.

Codage utilisé

Nous utilisons une population de N individus identifiés par un chromosome $\underline{\theta}_i$, $i \in [1, N]$, constitué par la suite des m paramètres à estimer. Chaque paramètre θ_j , $j \in [1, m]$, est codé par une liste finie de L gènes pouvant prendre des valeurs dans un alphabet binaire :

$$\underline{\theta}_i = (\underbrace{c_{11}^i, c_{12}^i, \dots, c_{1L}^i}_{\theta_1}; \underbrace{c_{21}^i, c_{22}^i, \dots, c_{2L}^i}_{\theta_2}; \dots; \underbrace{c_{m1}^i, c_{m2}^i, \dots, c_{mL}^i}_{\theta_m}) \quad (2.9)$$

Le codage retenu est un codage multiparamétré, concaténé, projeté, et à borne fixe [38]. Pour construire ce codage, il suffit de projeter linéairement l'entier de l'intervalle $[0, 2^L]$ vers l'intervalle $[\theta_{j_{\min}}, \theta_{j_{\max}}]$ pour chaque paramètre θ_j , $j \in [1, m]$. Pour chaque paramètre θ_j , la précision du codage π_j peut être calculée :

$$\pi_j = \frac{\theta_{j_{\max}} - \theta_{j_{\min}}}{2^L - 1} \quad (2.10)$$

Terminologie

Grossièrement, on peut dire que les chaînes des systèmes génétiques artificiels sont analogues aux chromosomes des systèmes biologiques. Dans les systèmes naturels, l'ensemble du matériel génétique est appelé le génotype. Dans les systèmes génétiques artificiels, l'ensemble des chaînes est appelé une structure. Dans les systèmes naturels, l'organisme formé par l'interaction de l'ensemble du matériel génétique avec son environnement est appelé le phénotype. Dans les systèmes génétiques artificiels, les structures décodées forment un ensemble de paramètres donné, ou une solution ou un point dans l'espace des solutions. Dans la terminologie naturelle, on dit que les chromosomes sont constitués de gènes, qui peuvent prendre différentes valeurs que l'on appelle allèles. Dans l'exploration génétique artificielle, on dit que les chaînes se composent de traits ou détecteurs qui prennent différentes valeurs. Les traits peuvent être localisés en différentes positions sur la chaîne.

2.4.2 Comparaison avec les autres techniques d'optimisation

Les règles de transition des algorithmes génétiques sont stochastiques alors que la plupart des autres méthodes ont des règles de transition déterministes comme la descente du gradient. Il y a cependant une différence entre les opérateurs pseudo-aléatoires des algorithmes génétiques et d'autres méthodes pour lesquelles seul le hasard intervient pour guider une exploration. Les AG s'appuient sur le hasard pour guider une exploration tout en tirant grandement partie de l'information disponible. Plus précisément, les AG produisent des échanges d'informations entre les chaînes, et cherchent des relations de cause à effet entre ces similarités et les performances élevées [38].

Une autre technique d'exploration, indépendante de l'initialisation, présentée au paragraphe 2.3, le recuit simulé, comprend aussi un processus aléatoire pour guider la recherche d'états d'énergie minimale. Cependant, dans le cas qui nous intéresse de l'estimation bayésienne des paramètres de déformation du modèle statistique défini *a priori*, soit la recherche de la solution optimale minimisant une fonctionnelle d'énergie de plusieurs variables continues, les avantages des AG sur le recuit simulé sont nombreux. Nous pouvons mettre en avant les aspects suivants :

- les algorithmes génétiques optimisent un ensemble de points contrairement au recuit simulé qui optimise à chaque itération un point unique³. Les AG ont donc la propriété d'être massivement parallélisables, car on peut évaluer en parallèle les valeurs d'adaptation des différentes chaînes d'une même génération.
- tout comme le recuit simulé, les AG ne sont pas limités par des hypothèses contraignantes sur la continuité, l'existence de dérivés, l'unimodalité entre autres de la fonction à optimiser. Contrairement au

3. Mis à part, la technique de recuit simulé parallèle.

recuit simulé, les AG ont par contre la faculté de s'adapter automatiquement au type de la fonction à optimiser. Ainsi, peu d'itérations sont nécessaires pour optimiser une fonction unimodale simple. L'optimisation d'une fonction plus complexe, multimodale, nécessitera un peu plus d'itérations. Cette caractéristique n'existe pas avec le recuit simulé et le temps de calcul de cette procédure est fonction du nombre d'itérations effectuées (lié en fait à la température initiale, la température finale, le taux de décroissance en température) et à la variation de la fonction d'énergie. Si cette décroissance suit une loi logarithmique suffisamment lente, alors la convergence vers l'optimum global est assurée. Malheureusement, cette loi de descente est beaucoup trop lente en pratique. On lui préfère une loi de descente exponentielle, plus rapide, mais n'assurant pas la convergence vers le minimum global. Dans l'exemple que nous avons présenté au paragraphe 2.3.1, ce taux a été déterminé de façon heuristique afin d'assurer la convergence de tous les cas testés. Rien ne prouve que l'optimum global soit atteint pour un autre exemple.

- dans notre application, la fonction à optimiser dépend des caractéristiques extraites de l'image SONAR segmentée en deux classes (*ombre/réverbération*) et non pas directement de l'image originale bruitée. La fonction à optimiser est ainsi plutôt du type multimodale; chaque mode de cette fonction est associé à une ombre portée détectée sur l'image. L'amplitude de ces modes est proportionnelle au degré de ressemblance de notre modèle statistique défini *a priori* et de l'ombre portée détectée.

Les AG semblent particulièrement bien adaptés à l'optimisation de fonctions multimodales [38]. En effet, contrairement au recuit simulé qui optimise un point unique dans l'espace de recherche selon une règle de transition servant à déterminer le nouveau point, les AG considèrent simultanément un ensemble de points en "escaladant" plusieurs pics en parallèle. Ainsi, la probabilité de se fixer sur un faux sommet et donc de retenir une solution sous-optimale correspondant à un minimum local est plus réduite [38].

- Dans son principe, schéma de refroidissement combiné à une technique d'échantillonnage simulant une distribution de Gibbs, le recuit simulé est une procédure assez figée pour pouvoir intégrer facilement des informations spécifiques à un type de problème qui permettraient une convergence plus rapide vers l'optimum global. En revanche, les AG peuvent facilement exploiter une information auxiliaire et la connaissance propre à un problème particulier afin d'accélérer l'exploration génétique. C'est le cas de l'algorithme génétique hybride que nous avons développé. Il est décrit au paragraphe 2.4.3 [38].
- les AG induisent néanmoins un coût en programmation plus important qu'une procédure du type recuit simulé ainsi qu'un codage des paramètres.

2.4.3 Méthodes hybrides

Lorsque l'on dispose d'informations spécifiques à un problème, il peut être avantageux de considérer un AG hybride [38]. Les algorithmes génétiques peuvent être associés à un bon nombre de techniques d'exploration spécifiquement adaptées à un problème particulier. Peu d'auteurs ont proposé de telles hybridations avec publication de résultats effectifs. Néanmoins, l'idée est simple, intéressante, et peut être exploitée pour améliorer les performances finales de l'exploration génétique.

Nous avons présenté au paragraphe 2.2 une méthode de descente de gradient permettant de trouver des optima locaux. Pour développer un AG hybride, il suffit d'associer cette méthode d'exploration locale avec une exploration génétique. En un sens, l'AG isole les "collines" intéressantes de la fonction à optimiser et la méthode locale les "escalade". De cette façon, on peut combiner l'aspect stochastique et le parallélisme des AG avec le comportement plus déterministe de la technique locale. Il y a plusieurs moyens d'hybrider des AG.

- Une approche séquentielle consiste à faire fonctionner l'algorithme génétique lors d'une phase d'apprentissage; ensuite, la procédure d'optimisation locale peut intervenir avec comme initialisation, par exemple, les cinq ou dix meilleurs pour cent d'individus de la dernière génération.

- Une autre approche consiste à isoler à chaque génération les meilleurs individus d'une même génération. Ces derniers sont ensuite utilisés pour initialiser la procédure d'exploration locale. C'est cette dernière méthode que nous avons retenue.

2.4.4 Niche écologique

Au début de l'exécution d'un algorithme génétique, il est courant d'avoir quelques individus avec une très forte adaptation. Si l'on suit la règle de reproduction du paragraphe 2.4.1, ces individus s'attribueraient une proportion importante de la population finie d'une génération. Cela n'est pas souhaitable et s'avère même être l'une des causes principales de convergence prématurée (convergence vers un minimum local). Pour éviter une telle dérive génétique et maintenir à chaque itération de l'algorithme, c'est-à-dire à chaque génération, une certaine diversité dans la population, des méthodes fournissant un comportement reproduisant les phénomènes de niche écologique et de formation d'espèce⁴ ont été proposées. Ces méthodes maintiennent une certaine diversité dans la population produite par l'algorithme génétique, autorisant ainsi la formation de sous-populations stables dans des proportions liées à l'amplitude des pics correspondant dans la fonction à optimiser. Cette technique peut être également associée à la méthode d'exploration hybride décrite précédemment.

Un procédé particulier qui exploite la métaphore du partage pour induire des niches écologiques et des espèces est décrit en détail par Goldberg [38]. Selon ce procédé, une fonction de partage est définie afin de déterminer le degré de partage pour chaque chaîne de la population. Pour un individu donné, le degré de partage est donné par la somme des valeurs des fonctions de partage correspondant à toutes les autres chaînes de la population. Les chaînes proches d'un individu doivent avoir un haut degré de partage (proche de 1), et les chaînes éloignées de l'individu doivent avoir un degré de partage très petit (proche de 0). Après avoir additionné le nombre total de parts de cette manière, l'adaptation modifiée d'un individu est obtenue en divisant l'adaptation d'origine, la valeur avant partage, par la somme des valeurs de partage :

$$\mathcal{F}_p(\theta_i) = \frac{\mathcal{F}(\theta_i)}{\frac{1}{N} \sum_{j=1}^N d(\theta_i, \theta_j)} \quad (2.11)$$

Quand beaucoup d'individus sont dans le même voisinage (ou proches), ils contribuent mutuellement aux comptes de partage des uns et des autres, ce qui dégrade leur valeur d'adaptation. En conséquence, le mécanisme limite le développement incontrôlé de certaines espèces dans la population. Dans notre application, la fonction de partage entre les deux chaînes θ_i et θ_j est définie à chaque génération comme suit :

$$d(\theta_i, \theta_j) = \sum_{k=1}^m |\hat{\theta}_{ik} - \hat{\theta}_{jk}| \left(\frac{\theta_{k_{max}} - \theta_{k_{min}}}{2^L - 1} \right) \quad (2.12)$$

où θ_k est le $k^{\text{ième}}$ paramètre, $\theta_k \in [\theta_{k_{min}}, \theta_{k_{max}}]$, et $\hat{\theta}_{ik}$ est le $k^{\text{ième}}$ paramètre estimé et codé par le $i^{\text{ième}}$ chromosome, ou chaîne, $\hat{\theta}_i$.

2.4.5 Réajustement de la fonction d'adaptation

Précédemment, nous avons vu l'une des causes principales d'une éventuelle convergence prématurée. Nous avons présenté brièvement un mécanisme, proposé par Goldberg, inspiré par les mécanismes d'évolution des organismes vivants. Il a pour effet de limiter le développement incontrôlé de certaines espèces dans la population, et permet d'éviter une dérive génétique au début de la procédure d'exploration. A un stade plus avancé de cette exploration, le problème est bien différent. En effet, il est possible qu'il existe encore une certaine diversité dans la population. Cependant, l'adaptation moyenne de la population risque d'être proche de l'adaptation du meilleur individu. De ce fait, les individus moyens et les meilleurs induisent à

4. On peut se représenter une niche écologique comme la fonction ou le rôle d'un organisme dans un environnement donné, et on peut envisager l'espèce comme une classe d'organismes ayant des caractéristiques communes.

peu près le même nombre de copies dans les générations suivantes et l'optimum global n'est pas localisé précisément par cette procédure d'optimisation. La survie du plus adapté devient alors une exploration aléatoire parmi les individus de faible adaptation. Pour résoudre ce problème, un réajustement de la fonction d'adaptation, à chaque itération de l'algorithme, a été proposé par Goldberg [38]. Ce réajustement consiste en une transformation linéaire de la fonction d'adaptation :

$$\mathcal{F}'_{\max} = C_{\text{mult}} \mathcal{F}_{\text{moyen}} \quad (2.13)$$

où C_{mult} est un facteur multiplicatif permettant d'accroître l'étendue des valeurs prises par la fonction d'adaptation dans la population.

2.4.6 Descente en température

Pour résoudre ces deux questions, convergence prématurée et réajustement de la fonction d'adaptation, nous avons proposé une technique, inspirée de celle du recuit simulé, qui consiste à associer à la fonction à optimiser, un schéma de refroidissement en température. Rappelons que $\mathcal{F}$ représente la fonction à maximiser. Nous considérons, à chaque itération de l'exploration génétique, la nouvelle fonction $\mathcal{F}_{[T_k]}$ paramétrée par un facteur de température T_k :

$$\mathcal{F}_{[T_k]}(\underline{\theta}_i) = \mathcal{F}(\underline{\theta}_i, x)^{\frac{1}{T_k}} \quad (2.14)$$

$$= \exp\left\{-\frac{1}{T_k} \epsilon(\underline{\theta}_i, x)\right\} \quad (2.15)$$

avec T_k , une suite décroissante de paramètres strictement positifs, $\{T_k\}_{k \in \mathbb{N}}$ convergeant vers 0 suivant une loi exponentielle :

$$T_k = T_0 a^k \quad a > 0 \quad (2.16)$$

Dans notre application, k représente le nombre d'itérations effectuées, ou le nombre de générations créées, par l'algorithme. Ce schéma de refroidissement a pour effet d'accuser progressivement le relief énergétique de notre fonction d'adaptation $\mathcal{F}$. Ainsi, pour $T_k = 1$, on retrouve la fonction que l'on cherche à maximiser. Pour une température élevée, le relief énergétique de la fonction d'adaptation est lissée, ce qui empêche une domination précoce des individus extraordinaires (i.e., de forte adaptation) et évite ainsi une convergence prématurée en début d'exploration génétique. En revanche, lorsque la température T_k tend vers 0, cette procédure accuse le relief énergétique de la fonction d'adaptation, et permet d'accroître l'étendue des valeurs prises par la fonction d'adaptation dans la population. Cette technique encourage une compétition saine entre les différents individus d'adaptation presque égale, tout comme la technique décrite au §2.4.5.

2.4.7 Résultats expérimentaux

Les AG incluant les différentes stratégies hybrides décrites précédemment ont été appliqués à l'estimation de θ , les paramètres de la déformation appliquée au modèle statistique défini *a priori*. Rappelons que l'on cherche à maximiser la fonction $\mathcal{F}(\theta, x)$ relativement aux six composantes de θ . Les trois opérateurs utilisés, sélection, croisement, mutation, sont ceux décrits au §2.4.1. Le croisement adopté est un croisement un point [38]. Il est caractérisé par un taux de croisement P_{cross} . De même, le processus de mutation est spécifié par un taux de mutation P_{mut} . L'étape de recombinaison que nous avons choisie favorise l'élitisme ; le meilleur individu de chaque génération est préservé et remplace l'individu le moins bien adapté à la génération suivante (cf. tableau 2.3). Nous comparons les résultats obtenus par un AG élitiste, hybride, simple, et la même version de cet algorithme avec un réajustement de la fonction d'adaptation par niche écologique, d'une part, et associée à une descente en température, d'autre part.

a) AG hybride simple. La technique de convergence locale associée à la procédure d'exploration génétique est la descente de gradient à pas fixe décrite au §2.2. Nous avons choisi une approche parallèle de l'hybridation dans laquelle les cinq pour cent meilleurs individus de chaque génération sont ensuite exploités pour initialiser la procédure de descente de gradient.

b) AG hybride avec niche écologique. Nous utilisons la fonction de partage définie par la relation (2.12).

c) AG hybride avec descente en température. Nous adoptons une décroissance en température suivant une loi exponentielle indicée par le nombre d'itérations effectuées, ou le nombre de générations créées, par l'algorithme (cf. relation (2.16)). Les paramètres sont fixés aux valeurs suivantes : $T_0 = 3$, $a = 0.99$

Pour ces trois algorithmes, les paramètres de l'exploration génétique sont fixés aux valeurs suivantes : $L = 8$, $N = 100$, $P_{mut} = 0.08$, $P_{cross} = 0.8$, et on arrête l'algorithme après un nombre de générations maximum que l'on fixe à 250 (seuil).

□ **Algorithme** AG HYBRIDE AVEC DÉCROISSANCE EN TEMPÉRATURE

$\mathcal{F}$	Fonction d'adaptation
N	Nombre de chromosomes
P_{mut}	Probabilité de mutation
P_{cross}	Probabilité de croisement
seuil	Nombre maximal de générations
θ	Vecteur de paramètres de la déformation
T_0	Température initiale
a	Taux de refroidissement

– $T \leftarrow T_0$

– $k \leftarrow 0$

• Initialisation aléatoire des N chromosomes.

• Tant que $k < \text{seuil}$

◦ Évaluation de chaque chromosome :

$$\mathcal{F}_{[T_k]}(\underline{\theta}_i) = \exp\left\{-\frac{1}{T_k}\epsilon(\underline{\theta}_i, x)\right\}$$

◦ Descente de gradient pour les 5 % meilleures chaînes.

◦ On remplace la chaîne la moins bien adaptée par la meilleure chaîne obtenue à l'itération précédente.

◦ croisement un point, avec la probabilité P_{cross} , et mutation avec la probabilité P_{mut} .

◦ Faire décroître la température, $T_{k+1} = aT_k$, et incrémenter l'itération $k = k + 1$.

TAB. 2.3 – Optimisation de θ par algorithme génétique hybride avec décroissance de température.

Nous avons rassemblé dans le tableau 2.4, les énergies minimales obtenues par ces trois algorithmes sur neuf images. Nous avons aussi indiqué en indice la génération dont est issue chaque estimation.

	Image de la figure				
AG élitiste hybride	2.17.a	2.17.b	2.17.c	2.17.g	2.20.h
<i>a- simple</i>	0.14 ₃₅	0.10 ₇₅	0.16 ₁₄₀	0.24 ₁₀₀	0.26 ₂₄₅
<i>b- avec niche écologique</i>	0.13 ₅₅	0.10 ₁₃₀	0.21 ₇₅	0.20 ₂₂₀	0.23 ₃₀
<i>c- avec décroissance de température</i>	0.13 ₁₆₀	0.10 ₁₇₅	0.17 ₂₀	0.15 ₂₃₀	0.22 ₇₅

TAB. 2.4 – *Énergies finales obtenues (E_k où E désigne l'énergie et k l'itération) par les différentes procédures dédiées à l'optimisation de θ et fondées sur les AG hybrides.*

Dans le cas de l'optimisation de fonctions simples, en particulier les fonctions unimodales pour lesquelles l'image segmentée, contient l'ombre portée d'un objet de forme géométrique très simple, comme celle par exemple d'une mine cylindrique sur fond de sable (cf. figures 2.17.a/b), les résultats obtenus par les trois algorithmes sont assez similaires. Par contre, pour des fonctions plus complexes, en particulier pour les fonctions multimodales associées aux images segmentées sur lesquelles figurent des ombres portées de rochers et de mines (cf. figure 2.17.c) avec occultations partielles (cf. figure 2.17.g), ou sur lesquelles apparaissent des ombres portées d'objets manufacturés dont les formes géométriques ne sont pas aussi simples qu'un cylindre (cf. figure 2.20.h), les résultats obtenus par un AG hybride élitiste avec décroissance de température sont meilleurs, exception faite pour l'exemple de la figure 2.17.c où elle est comparable, et les estimations finales, plus proches du minimum global.

Les figures 2.8, 2.9, 2.10, 2.11, 2.16 présentent des étapes intermédiaires de l'exploration génétique hybride, avec décroissance de température, dédiée à l'optimisation de θ pour différentes images SONAR synthétiques ou réelles et pour un modèle d'ombre correspondant à un objet cylindrique ou de forme géométrique simple. Le résultat atteint à l'itération, ou génération, courante pour l'estimation de θ est montré sur la partie droite des figures. La partie gauche contient les cinq pour cent meilleurs individus présents à l'itération considérée. Ces dernières sont aussi utilisées pour initialiser la procédure d'exploration locale de descente du gradient. Nous avons placé également dans les figures 2.12, 2.13, 2.14, 2.15 les résultats obtenus pour un modèle d'ombre portée correspondant à un objet sphérique. Dans tous les cas testés, cette méthode permet d'estimer θ avec une aussi bonne précision que le recuit simulé et a l'avantage d'être trente fois plus rapide. Elle requiert entre quinze secondes et quarante cinq secondes de calcul selon la complexité de la fonction à minimiser sur une station de travail IBM 43P.

Nous avons présenté dans ce paragraphe les résultats de détection et de classification obtenus sur quelques images SONAR (cf. figures 2.17, 2.18, 2.19, 2.20, 2.21). En ce qui concerne l'étape de classification, nous avons adopté la règle résumée dans le tableau 2.5 pour le modèle statistique correspondant à l'ombre portée associé à l'objet manufacturé ou sphérique.

Classe	Objet cylindrique/sphérique	doute	objet naturel
$\epsilon(\theta, x)$	$\epsilon \leq 0.19$	$0.19 \leq \epsilon < 0.23$	$0.23 < \epsilon$

TAB. 2.5 – *Classification en fonction des valeurs de $\epsilon(\theta, x)$.*




FIG. 2.8 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (a) Segmentation en deux classes (ombre/réverbération) de l'image présentée en (b) comportant les ombre de rochers et d'une mine cylindrique, avec occultations partielles. (b) Initialisation du modèle; 5 % meilleures estimations à gauche et meilleure estimation après descente de gradient à droite. (b-e) Étapes intermédiaires de l'exploration génétique hybride, respectivement, itération numéro 0, 2, 4, 20, 46. (f) Détection finale : $\epsilon = 0.15$ et classification de l'ombre portée de cet objet en "ombre de mine cylindrique ou d'objet manufacturé".




FIG. 2.9 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (a) Segmentation en deux classes (ombre/réverbération) de l'image présentée en (b) comportant l'ombre portée d'un objet manufacturé de forme complexe (une mine cylindrique et son chariot porteur). (b) Initialisation du modèle; 5 % meilleures estimations à gauche et meilleure estimation après descente de gradient à droite. (b-e) Étapes intermédiaires de l'exploration génétique hybride, respectivement, itération numéro 0, 2, 8, 14, 16. (f) Détection finale. La zone détectée par cette méthode est l'ombre portée de la partie frontale de la mine (de forme géométrique simple). L'énergie finale de valeur $\epsilon = 0.22$ permet de classer cette ombre portée en "ombre de mine cylindrique ou d'objet manufacturé" avec néanmoins une assez faible certitude; dans ce cas, l'avis final d'un expert est indispensable.




FIG. 2.10 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (a) Segmentation en deux classes (ombre/réverbération) de l'image présentée en (b) comportant l'ombre portée d'une série de dune. (b) Initialisation du modèle ; 5 % meilleures estimations à gauche et meilleure estimation après descente de gradient à droite. (b-e) Étapes intermédiaires de l'exploration génétique hybride, respectivement, itération numéro 0, 2, 8, 14, 16. (f) Détection finale. Dans cet exemple, l'énergie élevée obtenue $\epsilon = 0.41$ indique une faible "ressemblance" entre la forme prototype définie a priori et la zone d'intérêt détectée dans l'image. L'ombre portée de cet objet est classée, à juste titre, comme étant celle d'un "objet naturel".




FIG. 2.11 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (a) Segmentation en deux classes (ombre/réverbération) de l'image synthétique présentée en (b) comportant l'ombre portée synthétique d'une mine cylindrique partiellement occultée par l'ombre d'une dune. (b) Initialisation du modèle ; 5 % meilleures estimations à gauche et meilleure estimation après descente de gradient à droite. (b-e) Étapes intermédiaires de l'exploration génétique hybride, respectivement, itération numéro 0, 2, 4, 16, 30. (f) Détection finale. La zone détectée est bien l'ombre de la mine. $\epsilon = 0.06$.




FIG. 2.12 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (Modèle d'ombre portée associée à un objet sphérique). (a) Segmentation en deux classes (ombre/réverbération) de l'image synthétique présentée en (b) comportant l'ombre portée créée par des cailloux et des rochers et ombre portée d'une mine sphérique rajoutée synthétiquement. (b) Initialisation du modèle; 5 % meilleures estimations à gauche et meilleure estimation après descente de gradient à droite. (b-e) Étapes intermédiaires de l'exploration génétique hybride, respectivement, itération numéro 0, 4, 6, 8, 24. (f) Détection finale. La zone détectée est bien l'ombre de la mine sphérique. $\epsilon = 0.10$. Classification: "ombre de mine sphérique".




FIG. 2.13 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (Modèle d'ombre portée associée à un objet sphérique). (a) Segmentation en deux classes (ombre/réverbération) de l'image synthétique présentée en (b) comportant l'ombre portée créée par des cailloux et des rochers et ombre portée d'une mine sphérique rajoutée synthétiquement. (b) Initialisation du modèle; 5 % meilleures estimations à gauche et meilleure estimation après descente de gradient à droite. (b-e) Étapes intermédiaires de l'exploration génétique hybride, respectivement, itération numéro 0, 1, 2, 16, 26. (f) Détection finale. L'algorithme a trouvé entre deux zones intéressantes pour finalement sélectionner la zone correspondant à l'ombre de la mine sphérique. $\epsilon = 0.15$. Classification: "ombre de mine sphérique".




FIG. 2.14 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (Modèle d'ombre portée associée à un objet sphérique). (a) Segmentation en deux classes de l'image présentée en (b) comportant l'ombre d'une mine sphérique rajoutée synthétiquement sur cette image réelle et mélangé par les ombres portées créées par des rides de sables. (b) Détection finale. Cet exemple nous montre l'efficacité de la méthode de détection/classification proposée lors d'une occultation importante de l'ombre portée à classer. Malgré d'importantes occlusions, la valeur faible de l'énergie finale atteinte par la procédure d'optimisation, $\epsilon = 0.19$, permet de classer cette ombre portée en "ombre portée d'objet sphérique et d'objet manufacturé".




FIG. 2.15 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (Modèle d'ombre portée associée à un objet sphérique). (a) Segmentation en deux classes de l'image présentée en (b) comportant l'ombres de rochers et d'un objet sphérique, rajoutée synthétiquement sur l'image réelle et partiellement occultée. (b) Détection finale. La région délimitée par le modèle statistique correspond bien à l'ombre portée de l'objet sphérique. L'énergie faible obtenue $\epsilon = 0.11$ permet de classer cette région détectée comme appartenant à l'ombre d'un objet sphérique.




FIG. 2.16 – Détection/classification par modèle statistique et optimisation par algorithme génétique élitiste hybride avec décroissance en température. (Modèle d'ombre portée associée à un objet sphérique). (a) Segmentation en deux classes de l'image présentée en (b) comportant l'ombre de rochers. (b) Détection finale. Dans cet exemple, l'énergie élevée obtenue par la procédure d'optimisation, $\epsilon = 0.55$, indique une faible "ressemblance" entre la forme prototype définie a priori et la zone d'intérêt détectée dans l'image. L'algorithme permet de conclure qu'aucun objet sphérique n'est présent dans cette image.




FIG. 2.17 – Classe objet manufacturé. La méthode proposée a permis de classer sans ambiguïté ces ombres portées en "ombre portée d'objet manufacturé". En l'occurrence, il s'agit d'objets cylindriques. Certains d'entre eux sont constitués de deux parties cylindriques (cf. figures d, f).




FIG. 2.18 – **Classe objet manufacturé.** Dans ces deux images, l'algorithme a trouvé deux objets manufacturés. Il a détecté l'ombre portée de l'un des tronçons cylindriques du pipe-line (figure a), et l'ombre portée d'une partie géométrique de la carcasse d'un bateau (figure b).




FIG. 2.19 – **Classe objet sphérique.** L'algorithme a détecté et identifié correctement sur ces images les différentes ombres portées synthétiques associées aux mines sphériques.




FIG. 2.20 – **Classe doute.** La méthode proposée a classé ces zones comme "douteuses". Un expert demeure indispensable pour trancher et classer ces différents objets en "objet manufacturé" (a) et en "objet naturel" (b, c, d).




FIG. 2.21 – *Aucune ambiguïté, aucun objet manufacturé ou objet sphérique présent dans ces images. (a) $\epsilon=0.40$. (b) $\epsilon=0.41$. (c) $\epsilon=0.24$. (d) $\epsilon=0.55$. (e) $\epsilon=0.57$. (f) $\epsilon=0.38$.*

2.5 Conclusion

Dans ce chapitre, nous avons présenté trois algorithmes d'optimisation dédiés à l'estimation au sens du MAP de θ , le vecteur des paramètres de la déformation appliquée au modèle statistique recherché dans l'image.

Le premier, basé sur une descente de gradient, a l'avantage d'être rapide mais fournit dans quelques cas une solution sous-optimale difficilement exploitable pour la phase de classification. Le deuxième, qui utilise le recuit simulé, est simple à mettre en œuvre et permet d'obtenir une bonne estimation de θ , très proche du minimum global, mais au prix d'un coût calcul rédhibitoire, entre cinq et huit minutes pour chaque estimation. La troisième méthode, basée sur une exploration génétique associée à une technique d'exploration locale de type descente de gradient et à un schéma de descente en température, semble être particulièrement bien adaptée aux spécificités de notre problème. Cette méthode a l'avantage d'être rapide, entre quinze secondes et trente secondes selon la complexité de la fonction à minimiser, et permet d'estimer θ avec une aussi bonne précision que le recuit simulé.

Conclusion

L'étude décrite dans cette partie propose un cadre statistique de modélisation d'objets bidimensionnels pour la classification *non supervisée* des ombres portées en imagerie SONAR.

L'approche originale que nous avons adoptée utilise les modèles statistiques et repose sur une formulation bayésienne du problème, intégrant la définition d'une forme prototype à laquelle sont appliquées des déformations linéaires. La vraisemblance des observations exploite des informations extraites d'une segmentation en deux classes, markovienne hiérarchique non supervisée. Dans ce cadre, le problème de la détection et de la classification d'objets est équivalent à un problème d'estimation bayésienne des paramètres de déformation du modèle. Cette estimation conduit à la minimisation d'une fonction d'énergie globale non linéaire. Cette minimisation est réalisée efficacement par une procédure d'exploration génétique associée à une technique d'exploration locale par descente du gradient, et à un facteur de décroissance en température. La valeur de l'énergie obtenu par cette procédure d'optimisation permet ensuite de classer ou non l'objet détecté dans la classe d'objets considérée *a priori*. Cette technique de détection et classification a été validée avec succès sur une base test comportant soixante images SONAR de taille 256×256 pixels. Le cadre de modélisation retenu et les solutions algorithmiques introduites sont suffisamment généraux pour s'appliquer à une large classe de modèles statistiques et pour d'autres applications en reconnaissance des formes. Nous avons illustré cette partie de nombreux résultats expérimentaux, attestant la validité et la pertinence de la méthode proposée. Ces résultats démontrent que cette technique reste opérationnelle lorsque l'ombre portée à classer est occultée par l'ombre portée d'autres objets, cailloux ou rides de sable par exemple. Dans ces cas, la valeur finale de l'énergie après minimisation est un peu plus élevée que celle obtenue dans des situations sans occultations, mais reste suffisamment significative, c'est-à-dire assez faible pour un objet appartenant à la classe d'objets considérée et assez élevée dans le cas contraire, pour produire une classification adéquate. Néanmoins, afin de conforter cette phase d'identification des ombres portées, l'information liée à la texture du fond marin peut se révéler utile, et constitue l'objet de la partie suivante de ce document.

Quatrième partie

Classification des fonds marins

Chapitre 1

Segmentation et classification des fonds marins

1.1 Introduction

Une des applications de l'imagerie SONAR est la segmentation et la classification automatique des fonds marins. Segmenter une image consiste à produire une partition de l'image en régions possédant certaines caractéristiques d'homogénéité et correspondant aux différentes composantes de la scène. Précédemment, nous avons vu que cette segmentation pouvait se faire au sens des niveaux de gris, et permettait ainsi de détecter trois types de régions homogènes correspondant respectivement aux régions d'ombre, de réverbération de fond, et d'écho. La segmentation proposée dans ce chapitre a pour but de diviser l'image acoustique en régions "géologiquement" différentes. L'étape suivante (classification) consiste à identifier ces régions selon cinq classes correspondant aux cinq types de fond marin habituellement rencontrés à savoir, sables, cailloux, rochers, rides ou dunes de sable.

La classification des fonds marins peut être d'un grand intérêt pour les géologues ou les militaires. Elle peut être utilisée dans l'optique d'une expertise géologique (cartographie des fonds marins, exploitation des fonds marins, ...), l'ingénierie marine (pour l'installation des pipelines ou des câbles sous marins, ...) ou pour des applications militaires (guerre des mines, ...).

Une procédure classique de segmentation et de classification des fonds marins consiste en 1) une acquisition de données, 2) éventuellement un pré-traitement (correction de contraste, réduction de dynamique, correction géométrique, etc.), 3) une étape d'extraction des caractéristiques calculées sur des petites fenêtres locales, appelées imagerie dans la suite, 4) la sélection d'un classifieur (avec un apprentissage si l'algorithme de classification sélectionné est supervisé) et finalement, 5) une classification des imagerie.

- Pour l'étape d'extraction de caractéristiques, une approche classique utilisée en imagerie SONAR consiste à considérer l'image comme hautement texturée. Sous cette hypothèse, on peut utiliser, comme attributs caractéristiques, directement l'ensemble des niveaux de gris de cette image [11], ou des paramètres texturaux calculés sur celle-ci, telles que les matrices de cooccurrence [96, 107], les matrices de longueur de plage [95], les paramètres extraits d'un modèle autoregressif 1D [20] ou 2D [97], des mesures spectrales [95, 100] ou fractales [16].

L'image que l'on doit traiter est cependant fortement perturbée par le bruit de speckle et le bruit propre à chaque SONAR. Ce dernier est assez différent pour chaque type de SONAR, plus ou moins important selon l'importance des lobes secondaires, l'angle d'incidence du SONAR, la directivité du lobe principal, le gain du SONAR, les pré-traitements réalisés, etc. Les mesures texturales calculées directement à partir des niveaux de gris de l'image peuvent donc varier en fonction du SONAR utilisé, et risquent de ne pas être très représentatives d'un type de fond marin. De ce fait, des erreurs de classification peuvent en découler.

L'approche que nous avons adoptée dans cette étude consiste à utiliser non pas l'ensemble des niveaux de gris de l'image, mais une segmentation en deux classes de cette image (*ombre/réverbération*) et une approche exploitant une méthodologie de type "reconnaissance des formes". Nous avons proposé d'analyser et de

caractériser, par des mesures pertinentes, les formes d’ombres portées que produit chaque type de fond.

- Pour l’étape de classification, deux approches différentes ont été utilisées jusqu’à présent en imagerie SONAR. Il s’agit d’une part des méthodes statistiques de classification, telles que l’algorithme des K -moyennes [96], les méthodes de classification au sens du Maximum de Vraisemblance (MV) [20] ou du Maximum *A Posteriori* (MAP), et d’autre part, des réseaux neuronaux [11, 107, 95, 97, 100, 51, 1, 2]. Le problème majeur des approches statistiques, comme les classifieurs MV ou MAP, est qu’elles supposent que la densité de probabilité (DDP) de chacune des classes est connue et que les paramètres associés à celle-ci sont calculables. L’algorithme des K -moyennes, quant à lui, est non supervisé et ne nécessite pas de connaître la DDP de chacune des classes. Néanmoins, cette approche suppose, souvent à tort, la présence de “clusters” sphériques, d’égal volume et de faible inertie. Contrairement aux méthodes statistiques, le classifieur neuronal ne fait aucune hypothèse *a priori* sur la nature des DDPs associées aux différentes classes. Cependant, cette méthode nécessite une grande base de données suffisamment représentative pour l’apprentissage du classifieur. Dans notre application, ces données ne sont pas suffisantes pour mener à bien la phase d’apprentissage de l’algorithme. De même, on ne dispose pas de connaissances suffisantes pour modéliser par une DDP les mesures caractéristiques associées à chaque type de fond marin, et ainsi utiliser avec profit les méthodes statistiques comme les classifieurs MV ou MAP.

L’approche adoptée dans cette étude consiste à exploiter une connaissance *a priori* sur les formes d’ombres portées créées par chaque type de fond marin, et à associer à cette connaissance *a priori* une méthode de classification floue.

Enfin, dans le cadre d’une méthode classique d’extraction de caractéristiques et ensuite de classification, les paramètres sont calculés sur une petite fenêtre locale (ou imagerie). Ces imageries sont ensuite classées indépendamment les unes des autres. Cette méthode ne s’appuie sur aucun modèle statistique global de segmentation et ne prend pas en compte les mesures caractéristiques calculées sur les imageries adjacentes. Cette information contextuelle est néanmoins importante et peut constituer une information supplémentaire pertinente que l’on doit prendre en compte si l’on veut obtenir une carte de segmentation précise et fiable. À cette fin, on peut utiliser efficacement un modèle de segmentation markovien pour spécifier les dépendances spatiales entre imageries.

Nous proposons un modèle markovien pour la segmentation et la classification des fonds marins en imagerie SONAR. Notre approche utilise une information *a priori* sur les formes d’ombres portées créées par chaque type de fond, et associe à cette connaissance *a priori* une méthode de classification floue. Un modèle markovien est introduit pour imposer des contraintes *a priori* sur la carte de segmentation. La segmentation optimale est définie au sens du Maximum *a Posteriori* (MAP), et est estimée grâce à un algorithme de relaxation déterministe. Ce chapitre est organisé de la façon suivante. La section 1.2 décrit l’étape d’extraction des caractéristiques, les sections 1.3 et 1.4 présentent la classification floue et le modèle de segmentation utilisé. La section 1.5 contient des résultats de segmentation et de classification obtenus sur des images SONAR réelles.

1.2 Étape d’extraction de caractéristiques

L’étape d’extraction des caractéristiques introduite n’utilise pas directement l’ensemble des niveaux de gris de l’image, mais exploite la segmentation préalable de l’image SONAR en deux classes (*ombre/réverbération*). Plus précisément, ces caractéristiques sont issues d’une image SONAR segmentée, filtrée passe-haut, puis binarisée afin d’extraire les contours de chaque ombre portée. L’image résultante est ensuite subdivisée en imageries sur lesquelles un vecteur de caractéristiques est extrait. Les attributs calculés doivent être pertinents et permettre de caractériser et distinguer efficacement les ombres portées créées par des rides ou des dunes de sable (ombres allongées et parallèles) des ombres portées créées par des cailloux ou des rochers (ombres aux contours et aux orientations aléatoires). Pour chaque ombre portée contenue dans une imagerie, on calcule les caractéristiques ou attributs géométriques suivants.

- **Compacité**

C'est une caractéristique géométrique sans dimension qui mesure le degré de compacité d'une forme. Cette mesure est définie par :

$$C = \frac{4\pi S}{l^2} \quad (1.1)$$

où l et S représentent respectivement le périmètre et la surface de la forme. Cette mesure donne une idée de la complexité de la forme étudiée. Ce paramètre est égal à un pour une ombre portée circulaire et est proche de zéro pour une ombre portée chahutée ou très allongée.

- **Élongation**

On évalue l'élongation de la forme. Ce paramètre est calculé à partir des valeurs propres de la matrice de corrélation, elle-même calculée à partir de l'ensemble des points (x_s, y_s) des contours des ombres portées. La matrice de corrélation $\mathcal{C}$ est donnée par :

$$\mathcal{C} = \begin{pmatrix} c_{xx} & c_{xy} \\ c_{xy} & c_{yy} \end{pmatrix} \quad (1.2)$$

avec :

$$c_{xx} = \frac{1}{N_\Gamma} \sum_{s \in \Gamma} (x_s - x_G)^2 \quad (1.3)$$

$$c_{yy} = \frac{1}{N_\Gamma} \sum_{s \in \Gamma} (y_s - y_G)^2 \quad (1.4)$$

$$c_{xy} = \frac{1}{N_\Gamma} \sum_{s \in \Gamma} (x_s - x_G)(y_s - y_G) \quad (1.5)$$

où N_Γ et (x_G, y_G) notent respectivement le nombre de pixels du contour Γ et son barycentre. Les deux valeurs propres de la matrice de corrélation $\mathcal{C}$ sont données par :

$$\sigma_1 = \frac{1}{2} \left(c_{xx} + c_{yy} + \sqrt{(c_{xx} - c_{yy})^2 + 4c_{xy}^2} \right) \quad (1.6)$$

$$\sigma_2 = \frac{1}{2} \left(c_{xx} + c_{yy} - \sqrt{(c_{xx} - c_{yy})^2 + 4c_{xy}^2} \right) \quad (1.7)$$

Le paramètre d'élongation ξ s'en déduit et est défini par la relation suivante :

$$\xi = \sqrt{\frac{\sigma_1}{\sigma_2}} \quad (1.8)$$

- **Orientation**

On calcule l'orientation de l'axe principal de la forme. Ce paramètre se déduit des paramètres de la matrice de corrélation et de ses valeurs propres. Il est défini par un angle α avec l'axe des x :

$$\alpha = \arctan \left(\frac{\sigma_1 - c_{xx}}{c_{xy}} \right) \quad (1.9)$$

Finalement, quatre caractéristiques, invariantes en translation et rotation, ont été adoptées pour leur caractère discriminant. Elles se déduisent des attributs géométriques calculés précédemment pour chaque ombre portée détectée dans une imagerie. Ces caractéristiques sont pour chaque imagerie :

1) La compacité moyenne

La compacité moyenne des différentes ombres portées existant dans l'imagette considérée est donnée par :

$$C_{moy} = \frac{1}{M} \sum_{i=1}^M C_i \quad (1.10)$$

où M désigne le nombre de contours (ou d'ombres portées) existant dans l'imagette.

2) La directivité

On calcule la variance des orientations associées aux différents contours existant dans l'imagette. Ce paramètre nous permet de savoir si les différentes formes détectées dans l'imagette ont une orientation commune :

$$\sigma_\alpha^2 = \frac{1}{M} \sum_{i=1}^M (\alpha_i - \bar{\alpha})^2 \quad (1.11)$$

$$\text{avec} \quad \bar{\alpha} = \frac{1}{M} \sum_{i=1}^M \alpha_i \quad (1.12)$$

3) L'élongation maximale

On recherche l'élongation maximale rencontrée dans l'imagette considérée :

$$\xi_{max} = \max_{i \in [0, M]} \xi_i \quad (1.13)$$

4) La taille maximale

On recherche la taille maximale des contours présents dans l'imagette considérée :

$$N_{max} = \arg \max_{i \in [0, M]} N_{\Gamma_i} \quad (1.14)$$

Ainsi à chaque imagette est associé un vecteur de caractéristiques qui est ensuite utilisé par le classifieur flou décrit dans la section suivante.

1.3 Classification floue

Le classifieur flou utilisé dans notre application permet de prendre en compte la dispersion topologique des mesures, calculées en section 1.2, dans l'espace des caractéristiques, ainsi que la présence de nuages de points, associés aux différentes classes recherchées, aux limites mal définies [9]. Ce formalisme est particulièrement bien adapté à notre application pour appréhender le mélange de classes que l'on peut trouver dans une imagette donnée. Ajoutons aussi que la notion même de classe, dans cette application, reste vague et floue.

Appelons x_k le vecteur de caractéristiques associé à l'imagette k . x_k contient les quatre mesures géométriques présentées en section 1.2, soit $x_k = (F_{k1}, F_{k2}, F_{k3}, F_{k4}) = (C_{moy}, \sigma_\alpha^2, \xi_{max}, N_{max})$. Chaque vecteur x_k peut être affecté à l'une des cinq classes suivantes $\{w_0 = \text{sables}, w_1 = \text{rides}, w_2 = \text{dunes}, w_3 = \text{cailloux}, w_4 = \text{rochers}\}$ selon un degré d'appartenance $\mu_{w_i}(x_k)$, avec $0 \leq \mu_{w_i}(\cdot) \leq 1$. On suppose l'indépendance entre les différentes mesures géométriques F_{kj} et on appelle $\mu_{w_i}(F_{kj})$, la fonction d'appartenance associée à chaque paramètre statistique F_{kj} . La fonction d'appartenance $\mu_{w_i}(F_{kj})$ va quantifier empiriquement le fait que l'imagette k , de caractéristique géométrique F_{kj} , appartienne à la classe w_i . Si $\mu_{w_i}(F_{kj}) = 1$, cette confiance est totale et les

ombres portées détectées sont caractéristiques de la classe w_i . Si $\mu_{w_i}(F_{kj}) = 0$, cette confiance est nulle. Les fonctions d'appartenance que nous avons choisies sont classiques et de type exponentiel [9]. Elles permettent de représenter le caractère graduel et le passage progressif d'une classe à l'autre (cf. figure 1.1). Dans notre application, nous modélisons notre connaissance *a priori* sur les formes d'ombres portées créées par chaque type de fond marin par les quatre assertions suivantes.

1.) Les ombres portées créées par les rides (w_1) ou les dunes (w_2) ont une orientation commune, contrairement à celles créées par les cailloux (w_3) ou les rochers (w_4).

On définit, pour le paramètre σ_α^2 , les fonctions d'appartenance suivantes :

$$\mu_{w_1}(\sigma_\alpha^2) = \mu_{w_2}(\sigma_\alpha^2) \quad (1.15)$$

$$= \exp(-\lambda_1 \sigma_\alpha^2) \quad (1.16)$$

$$\mu_{w_3}(\sigma_\alpha^2) = \mu_{w_4}(\sigma_\alpha^2) \quad (1.17)$$

$$= \begin{cases} \exp[-\lambda_1(\lambda_2 - \sigma_\alpha^2)] & \text{si } \sigma_\alpha^2 < \lambda_1 \\ 1 & \text{sinon} \end{cases} \quad (1.18)$$

où λ_1, λ_2 sont des paramètres positifs définis empiriquement. $\lambda_1 = 10$, $\lambda_2 = 0.1$ dans notre application permettent de quantifier correctement le degré d'appartenance de chaque imagerie (de caractéristique σ_α^2) à chacune des classes w_i . La figure 1.1 représente le tracé de ces fonctions d'appartenance pour le paramètre σ_α^2 .




FIG. 1.1 – Tracé des fonctions d'appartenance pour le paramètre σ_α^2 .

2.) Les ombres portées créées par les rides (w_1) ou les dunes (w_2) ont une forme allongée contrairement à celles créées par les cailloux (w_3) ou les rochers (w_4).

On définit, pour le paramètre ξ_{max} , les fonctions d'appartenance suivantes :

$$\mu_{w_1}(\xi_{max}) = \begin{cases} \exp[-\lambda_4(\lambda_5 - \xi_{max})] & \text{si } \xi_{max} < \lambda_5 \\ 1 & \text{sinon} \end{cases} \quad (1.19)$$

$$\mu_{w_2}(\xi_{max}) = \begin{cases} \exp[-\lambda_4(\lambda_6 - \xi_{max})] & \text{si } \xi_{max} < \lambda_6 \\ 1 & \text{sinon} \end{cases} \quad (1.20)$$

$$\mu_{w_3}(\xi_{max}) = \mu_{w_4}(\xi_{max}) \quad (1.21)$$

$$= \begin{cases} \exp[-\lambda_4(\xi_{max} - \lambda_5)] & \text{si } \xi_{max} > \lambda_3 \\ 1 & \text{sinon} \end{cases} \quad (1.22)$$

où $\lambda_3, \lambda_4, \lambda_5$ sont des paramètres positifs. $\lambda_4 = 1, \lambda_5 = 7, \lambda_6 = 5$ ($\lambda_5 > \lambda_6$ car l'ombre portée créée par une ride de sable est plus allongée que celle créée par une dune).

3.) Les ombres portées créées par les rides (w_1) ou les dunes (w_2) ont une forme moins compacte que celles créées par les cailloux (w_3) ou les rochers (w_4).

On définit, pour le paramètre C_{moy} , les fonctions d'appartenance suivantes :

$$\mu_{w_1}(C_{moy}) = \mu_{w_2}(C_{moy}) \quad (1.23)$$

$$= \exp(-\lambda_6 C_{moy}) \quad (1.24)$$

$$\mu_{w_3}(C_{moy}) = \mu_{w_4}(C_{moy}) \quad (1.25)$$

$$= \begin{cases} \exp[-\lambda_6(\lambda_7 - C_{moy})] & \text{si } C_{moy} < \lambda_7 \\ 1 & \text{sinon} \end{cases} \quad (1.26)$$

où λ_6, λ_7 sont des paramètres positifs. $\lambda_6 = 5, \lambda_7 = 0.2$ dans notre application.

4.) L'ombre portée créée par un rocher (w_4) a une taille plus importante que celle créée par un cailloux (w_3).

On définit, pour le paramètre N_{max} , les fonctions d'appartenance suivantes :

$$\mu_{w_1}(N_{max}) = \mu_{w_2}(N_{max}) = 1 \quad (1.27)$$

$$\mu_{w_3}(N_{max}) = \begin{cases} \exp(\lambda_8 - N_{max}) & \text{si } N_{max} > \lambda_8 \\ 1 & \text{sinon} \end{cases} \quad (1.28)$$

$$\mu_{w_4}(N_{max}) = 1 - \mu_{w_3}(N_{max}) \quad (1.29)$$

où $\lambda_8 = 60$ dans notre application.

Le degré d'appartenance de chaque imagerie à chacune des classes $w_i, \mu_{w_i}(x_k) \ 0 < i \leq 4$, est ensuite donné par l'opérateur minimum [106] :

$$\mu_{w_i}(x_k) = \min\{\mu_{w_i}(F_{k1}), \dots, \mu_{w_i}(F_{k4})\} \quad 0 < i \leq 4 \quad (1.30)$$

Dans le cas d'une classification floue aveugle, ne prenant pas en compte le modèle statistique global de segmentation décrit en section 1.4, on affecte la classe w_i à l'imagerie k , telle que :

$$w_i = \arg \max_{w_i \in \{w_1, \dots, w_4\}} \{\mu_{w_i}(x_k)\} \quad (1.31)$$

On doit trouver un bon compromis quant à la taille de l'imagette utilisée pour la constitution du vecteur de caractéristiques x_k . Une petite imagette permet d'augmenter la précision de la carte de segmentation, mais ne permet pas de reconnaître efficacement les ombres portées de taille importante comme celle créées par certaines dunes de sable. La figure 1.6 nous montre un exemple de fond marin composé de dunes de sable qui illustre ce problème. Les ombres portées montrées sur cette image sont représentatives de la classe *dunes* ; elles possèdent tous une forme allongées et une orientation commune mais elles sont aussi de tailles très différentes. Des imagettes de petites dimensions centrées sur la zone d'ombre créée par la dune de la partie gauche de l'image ne seront pas classées *dunes* par notre méthode de classification floue aveugle mais plutôt classées *rochers* ou *sable*. Ce problème n'existe que pour la classe *dunes* pour laquelle les tailles des ombres portées issues d'une même image SONAR peuvent être très différentes. Pour résoudre ce problème, et toutefois garder une imagette de petite taille assurant une carte de segmentation précise, on peut effectuer une classification multiéchelle et prendre en compte le résultat de la classification floue aveugle obtenu pour une imagette de plus grande taille. La stratégie de classification utilisée dans notre application consiste alors à détecter la présence de la classe *dunes* pour cette imagette de grande taille par notre méthode de classification floue aveugle et projeter le résultat par duplication au niveau de classification le plus fin (cf. figure 1.2). L'extraction des caractéristiques et la classification des imagettes au niveau de résolution le plus fin se fait ensuite sur les imagettes qui n'ont pas été rangées dans la classe *dunes*.




FIG. 1.2 – Stratégie de classification multiéchelle sur les données.

1.4 Modèle de segmentation

Soit un couple de champs aléatoires (X, W) , avec $X = \{X_s, s \in S\}$, le champ des observations et $W = \{W_s, s \in S\}$, le champ des étiquettes, défini sur une grille rectangulaire S de N imagettes s . On notera $x = \{x_s, s \in S\}$ et $w = \{w_s, s \in S\}$ des réalisations de ces deux champs. x_s représente le vecteur d'attributs caractéristiques calculé sur chaque imagette, et w_s la variable cachée, affectée à l'imagette s , prenant ses valeurs dans l'ensemble $\{w_0 = \text{sables}, w_1 = \text{rides}, w_2 = \text{dunes}, w_3 = \text{cailloux}, w_4 = \text{rochers}\}$. La distribution de W , $P_W(w)$ est supposée être markovienne et stationnaire. Dans notre application, la segmentation de l'image SONAR en cinq zones de régions homogènes (sables, rides, dunes, cailloux, rochers) est vue comme un problème d'étiquetage bayésien au sens du Maximum a Posteriori (MAP) :

$$\hat{w} = \arg \max_w P_{W/X}(w/x) \quad (1.32)$$

Après application de la règle de Bayes, la précédente expression peut s'écrire :

$$\hat{w} = \arg \max_w \{ P_W(w) \cdot P_{X/W}(x/w) \} \quad (1.33)$$

En vertu du théorème de Hammersley et Clifford, W suit une distribution de Gibbs :

$$P_W(w) \triangleq \frac{1}{Z} \exp(-U_2(w)) \quad (1.34)$$

avec $U_2(w)$, la fonction d'énergie du modèle *a priori* et Z une constante de normalisation. En posant $P_{X/W}(x/w) = \exp(-U_1(w, x))$, on voit que $\hat{w}$ est le minimum global de la fonction d'énergie suivante :

$$U(w, x) = U_1(w, x) + U_2(w) \quad (1.35)$$

où $U_1(w, x)$ exprime l'adéquation entre les observations et les étiquettes.

- La contribution $U_2(w)$ à l'énergie globale correspond au modèle *a priori* qui spécifie les propriétés statistiques de la carte des étiquettes. Dans notre modèle de segmentation, nous privilégions les partitions en régions spatialement homogènes grâce à des potentiels d'interaction locale de la forme :

$$\beta_{st}(1 - \delta(w_s, w_t)) \quad (1.36)$$

Le système de voisinage retenu est un huit-voisinage, et seules les cliques à deux éléments sont considérées. β_{st} , égal à $\beta_1, \beta_2, \beta_3$ ou β_4 , désigne le paramètre associé respectivement aux cliques horizontales, verticales, diagonales droite et diagonales gauche (cf. figure 1.3). $\delta(\cdot)$ est la fonction de Kronecker. Sous ces conditions, l'énergie $U_2(w)$ peut s'écrire :

$$U_2(w) = \sum_{\langle s, t \rangle} \beta_{st}(1 - \delta(w_s, w_t)) \quad (1.37)$$




FIG. 1.3 – Cliques à deux éléments pour le voisinage du second ordre et paramètres associés.

- Notre modèle d'interaction entre observations et étiquettes, terme d'énergie $U_1(w, x)$, exploite le degré d'appartenance, $\mu_{w_i}(x_k)$, de la fenêtre k à la classe w_i . Cette mesure, comprise entre 0 et 1, est donnée par l'étape de classification présentée à la section 1.3. Le terme d'énergie $U_1(w, x)$ est défini comme suit :

$$U_1(w, x) = - \sum_{s \in S} \gamma(w_s, x_s) \quad (1.38)$$

où $\gamma(\cdot)$ est une fonction qui retourne $\mu_{w_s}(x_s)$ si $w_s = \arg \max_{w_j} (\mu_{w_j}(x_s))$ ($0 \leq j \leq 4$) et 0 sinon.

Finalement, l'estimation au sens du MAP de $\hat{w}$ conduit à la minimisation suivante :

$$\hat{w} = \arg \min_w \left\{ \underbrace{- \sum_{s \in S} \gamma(w_s, x_s)}_{U_1(w, x)} + \underbrace{\sum_{\langle s, t \rangle} \beta_{st} (1 - \delta(w_s, w_t))}_{U_2(w)} \right\}$$

On utilise l'algorithme de relaxation déterministe ICM pour minimiser cette fonction. Pour l'initialisation de cet algorithme, on exploite la carte de segmentation obtenue par la méthode de classification floue exposée à la section 1.3 (cf. tableau 1.1).

1.5 Résultats expérimentaux

Notre méthode de segmentation et de classification automatique des fonds marins a été évaluée sur des images SONAR réelles. Pour tous les résultats présentés, nous avons considéré une imagerie de dimension 64×64 pixels au niveau de classification le plus fin. Concrètement, cette imagerie délimite une zone de dimension $6,4 \times 6,4$ mètres. Pour la stratégie de classification multiéchelle décrite à la section 1.3, nous avons utilisé des images de taille 128×128 et 256×256 pixels respectivement. Les paramètres β_i ($0 < i \leq 4$) du modèle *a priori* ont été fixés à 0.2. Ce choix permet d'obtenir une bonne pondération entre le terme lié aux observations U_1 et le terme modélisant l'*a priori*.

Les figures 1.4, 1.5, 1.6, 1.7, 1.8, 1.9, 1.10.b représentent des images SONAR de fond marin et les résultats de classification obtenus par notre méthode. Des symboles représentant la classe affectée à chaque imagerie sont surimposées sur l'image originale. Ils sont centrés sur la fenêtre locale (ou imagerie). La convention suivante a été adoptée : aucun signe distinctif pour la classe *sables*, un petit carré pour la classe *cailloux*, un carré de taille plus importante pour la classe *rochers*, un petit segment de droite pour la classe *rides*, et deux segments parallèles pour la classe *dunes*.

Le résultat d'une classification floue, qui sert d'initialisation au processus de relaxation, ICM, est montrée à la figure 1.10.a, pour une image SONAR représentant un fond marin composé de rochers et de rides de sable. Comme on le constate, la non-prise en compte du modèle markovien *a priori* conduit à une segmentation et une classification partielles et bruitées. Le résultat obtenu par notre modèle de segmentation apparaît à la figure 1.10.b. Le terme *a priori* permet clairement de contraindre la cohérence spatiale de la segmentation et d'éliminer quelques erreurs de classification.

La figure 1.6 montre une image SONAR de taille 768×512 pixels de fond marin composé de dunes de sable qui illustre le problème de classification de la classe *dunes* exposée à la section 1.3. Dans cet exemple, la stratégie de classification multiéchelle permet de classer correctement, grâce aux images 256×256 , l'ombre portée créée par la dune de la partie gauche de l'image.

Quelques erreurs de classification existent pour les images situées sur les contours de l'image en raison du manque d'information contextuelle. Cependant, les résultats de segmentation présentés aux figures 1.4, 1.5, 1.6, 1.7, 1.8, 1.9, 1.10.b démontrent la validité et la robustesse de la méthode de segmentation et de classification proposée. Les différentes zones de fond marin sont correctement classées et les limites entre ces différentes régions sont correctement positionnées. Le temps de calcul, obtenu sur une station IBM 43P, est de l'ordre d'une dizaine de secondes pour une image de taille 512×768 pixels. Ce temps n'inclut pas le temps nécessaire à la segmentation en deux classes de l'image SONAR. A cette fin, on peut utiliser la méthode de segmentation SCM que nous avons proposé ou tout autres méthodes de segmentation binaire.

1.6 Conclusion

Nous avons développé un modèle statistique global pour la segmentation et la classification des fonds marins par imagerie SONAR. L'approche originale de segmentation que nous avons adoptée s'appuie sur une analyse

des formes d'ombres que produit chaque type de fond. Un modèle markovien permet de spécifier, d'une part, les propriétés d'homogénéité de la carte de segmentation recherchée, et d'autre part, d'exprimer la vraisemblance des observations issue d'un module de décision floue. Dans ce cadre, le problème de la segmentation et de la classification d'une image SONAR de fond marin est équivalent à un problème d'étiquetage bayésien, qui conduit à la minimisation d'une fonction d'énergie globale. Cette minimisation est réalisée dans notre application par un algorithme de relaxation déterministe. Les résultats obtenus sur des images SONAR réelles présentant des fonds marins de toute nature, ont montré la validité et l'intérêt de l'approche proposée.

□ **Algorithme** CLASSIFICATION DES FONDS MARINS

- | | |
|---------|---|
| $n + 1$ | Nombre de niveaux pour la classification multiéchelle |
| w | Champ des étiquettes |
| x | Champ des observations |
- Segmentation en deux classes de l'image SONAR et extraction des contours de chaque ombre portée détectée dans une imagerie.
 - $k \leftarrow n + 1$
 - Tant que $k > 0$
 - $k \leftarrow (k - 1)$
 - Calcul du vecteur de caractéristiques x_s associé à l'imagerie s .
 - Classification floue de chaque imagerie qui n'a pas été associée à la classe *dune* au niveau $k + 1$, résultat dans w^k .
 - Si $k = 0$, $w \leftarrow \text{ICM}(w, x)$
 - Si $k > 0$, alors duplication selon la stratégie décrite à la figure 1.2.
 $w^{k-1} \leftarrow \text{Duplication}(w^k)$

TAB. 1.1 – *Algorithme de segmentation et de classification des fonds marins.*




FIG. 1.4 – (a) Image des contours des ombres portées détectées sur l'image SONAR présentée en (b). (b) Image SONAR réelle représentant un fond marin composé de sables et de dunes de sable et classification obtenue par notre méthode surimposée sur l'image de droite.




FIG. 1.5 – Images SONAR réelles représentant un fond marin composé (a) de cailloux, (b) de sables, cailloux, et rochers. Les classifications obtenues par notre méthode sont surimposées sur ces images.



FIG. 1.6 – *Image SONAR réelle représentant un fond marin composé de dunes de sable et classification obtenue par notre méthode surimposée sur l'image.*




FIG. 1.7 – *Image SONAR réelle représentant un fond marin composé de rides de sable et classification obtenue par notre méthode surimposée sur l'image.*




FIG. 1.8 – Image SONAR réelle représentant un fond marin composé de sable et cailloux et résultat de la classification obtenue par notre méthode surimposée sur l'image.




FIG. 1.9 – Image SONAR réelle représentant un fond marin composé de sables, cailloux, et rides. Classification obtenue par notre méthode surimposée sur l'image.




FIG. 1.10 – (a) Image SONAR réelle représentant un fond marin composé de rochers et de rides avec une segmentation obtenue par une méthode de classification floue aveugle. (b) Classification obtenue par notre méthode surimposée sur l'image .

Conclusion générale et perspectives

Ce travail de recherche décrit une chaîne complète de détection et de classification automatique en imagerie SONAR. L'absence de réverbération du signal SONAR, définissant une zone d'ombre pour les différents objets reposant sur le fond marin constitue en fait le signal utile à détecter, puis à exploiter dans la phase de classification. L'approche proposée, pour les différentes étapes de cette chaîne de traitements, s'appuie sur la théorie bayésienne de la décision, ou de l'estimation, et associe à celle-ci une technique d'optimisation. Cette formulation bayésienne permet d'intégrer et de faire coopérer efficacement, au sein d'un même modèle statistique, un lien entre la solution recherchée et les observations issues de l'image SONAR, avec les connaissances *a priori* que l'on a sur cette solution.

▷ Pour une segmentation en deux classes (*ombre/réverbération*) de l'image SONAR, ces connaissances *a priori* sont locales et expriment le fait que les pixels voisins doivent avoir un niveau de gris similaire. Les champs de Markov permettent d'exprimer efficacement une telle régularité et cette information est codée localement par les potentiels de cliques.

▷ Dans le cas d'une segmentation en trois classes de l'image SONAR (*ombre/réverbération de fond/écho*), le modèle, défini *a priori*, intègre des informations à un niveau d'abstraction plus important, notamment au niveau région. Ces informations permettent de modéliser quelques propriétés physiques intéressantes liées à l'écho et notamment la dépendance spatiale de cette classe avec la classe *ombre*.

▷ Pour une classification des objets posés sur le fond marin, les connaissances *a priori* que l'on a sur la solution, sont globales et traduisent le fait que, contrairement à un objet naturel, un objet manufacturé crée une ombre portée dont la forme est très caractéristique. Cette connaissance *a priori* est décrite efficacement par un modèle statistique représentatif de l'ombre portée de la classe d'objet que l'on cherche à détecter.

▷ Enfin, dans le cadre d'une segmentation et d'une classification automatique des fonds marins, cette connaissance *a priori* est relative à une petite région (ou imagerie) de l'image SONAR. L'étape de classification exploite la connaissance sur les formes d'ombres portées créées par chaque type de fond marin à travers la spécification de potentiels appropriés. L'étape de segmentation prend en compte les propriétés statistiques d'homogénéité de la carte de segmentation des fonds marins recherchée.

Placés dans le contexte de l'estimation bayésienne, et de la recherche du MAP, chacun de ces problèmes conduit à la minimisation d'une fonction d'énergie non linéaire, non convexe, plus ou moins complexe, discrète ou continue, et associée à un nombre plus ou moins important de variables. Selon le type de fonction à minimiser, la stratégie d'optimisation optimale¹ que l'on doit utiliser est différente. Elle est quelquefois déterministe, monoéchelle dans le cas de l'ICM ou hiérarchique pour la technique multigrille, ou stochastique pour ce qui est de l'algorithme génétique. La contribution essentielle de ce travail est d'avoir défini, pour les différentes étapes de cette chaîne de traitements, un modèle statistique reposant sur une formulation bayésienne, et d'avoir proposé un algorithme de relaxation permettant de minimiser la fonction d'énergie associée à chacun de ces modèles. Plus précisément, les contributions suivantes peuvent être énumérées :

1. en terme de simplicité, de coût calculatoire et d'efficacité.

- La première partie de cette étude a été consacrée à l'**estimation** des paramètres du modèle markovien définie pour la segmentation non supervisée des images SONAR en deux classes, *ombre/réverbération*. Nous avons comparé plusieurs types de modélisation du bruit en imagerie SONAR [72, 74, 91, 78], et proposé un modèle de bruit reposant sur un mélange de lois de Weibull [78, 22]. Ce modèle de bruit s'est avéré très proche de la physique du phénomène observé, et plus juste, au sens du critère du χ^2 et de la distance de Kolmogorov, qu'une modélisation plus simple reposant sur les lois de Gauss ou de Rayleigh [81]. Contrairement aux algorithmes classiques d'estimation EM ou SEM, l'algorithme ECI permet une estimation efficace des paramètres associés à ce type de modélisation. Une solution originale au problème de l'initialisation de cet algorithme d'estimation itératif a été présentée [80]. Cette méthode basée sur l'algorithme des K -moyennes permet d'obtenir une bonne initialisation des paramètres du modèle de bruit et permet d'assurer une convergence rapide et efficace de la procédure ECI [33].

Une méthode d'estimation permettant d'estimer conjointement les paramètres du modèle du bruit et les paramètres du modèle du champ d'étiquettes dans une même procédure d'estimation conditionnelle itérative a alors été proposée. Cette dernière permet d'estimer ces paramètres au sens du MV pour le modèle du bruit et au sens des moindres carrés pour le modèle du champ d'étiquettes. Les tests sur images SONAR synthétiques et réelles sont venus confirmer l'intérêt de cet algorithme qui permet d'obtenir une estimation plus juste, au sens de la distance de Kolmogorov et du critère du χ^2 , de ces paramètres qu'une estimation non jointe. La précision des estimations obtenues ainsi que la convergence rapide de cette procédure, assurée dans tous les cas testés, a permis ensuite d'envisager une segmentation non supervisée en deux classes [74, 78].

- La deuxième partie de ce travail a porté sur la **segmentation** des images SONAR. Nous avons testé les algorithmes classiques monoéchelles existants. Nous avons vu que ceux-ci étaient, soit très rapides et sous-optimaux, soit relativement efficaces mais aussi très coûteux en temps de calcul. Nous nous sommes donc intéressés aux techniques déterministes, plus récentes qui associent une représentation statistique de l'image et une hiérarchisation de l'information. Nous avons montré que les méthodes hiérarchiques permettaient d'obtenir des améliorations, quant à la qualité de l'estimation et à la rapidité de l'algorithme, d'autant plus importantes que la fonction d'énergie que l'on cherche à minimiser est complexe [73].

Nous avons défini un modèle de segmentation spécifiquement adapté à notre application et intégrant des interactions spatiales et causal en échelle et associé à une stratégie de minimisation multigrille. Le modèle global, baptisé MCE pour Multigrille Causal en Échelle [77, 79], portant simultanément sur tous les niveaux de résolution de la pyramide des étiquettes, s'est avéré particulièrement robuste, comparativement aux autres méthodes de segmentation existantes, pour la segmentation des images SONAR présentant un bruit de speckle important. Nous avons vu que l'estimation des paramètres de ce modèle peut être réalisée efficacement et sans augmenter de façon trop importante le temps de calcul par la généralisation de l'estimateur proposé par Derin *et al.* Nous avons proposé une démarche originale pour segmenter une image SONAR en trois classes (*ombre/ réverbération de fond/écho*). Cette méthode tient compte du nombre peu élevé de pixels associés à la classe *écho*. Elle exploite les résultats issus d'une première segmentation MCE en deux classes. Le modèle utilisé tient compte de la vraisemblance des observations et intègre des informations *a priori* à différents niveaux de représentation, niveaux pixel et région. Les expérimentations sur des images SONAR synthétiques et réelles ont confirmé tout l'intérêt de ce modèle [74, 78].

- La troisième partie de ce travail a concerné la **classification** non supervisée des ombres portées en imagerie SONAR. L'approche originale que nous avons adoptée utilise aussi les modèles statistiques et repose à nouveau sur une formulation bayésienne du problème. Elle comprend la définition d'une forme prototype à laquelle sont appliquées des déformations géométriques linéaires. La vraisemblance des observations utilise des informations extraites d'une segmentation MCE non supervisée. Dans ce cadre, le problème de la classification d'un objet est équivalent à un problème d'estimation bayésien des paramètres de déformation du modèle. Cette estimation conduit à la minimisation d'une fonction d'énergie globale non linéaire. Cette minimisation est réalisée dans notre application par une procédure d'optimisation génétique associée à une technique d'exploration locale par descente du gradient, et à un facteur de décroissance en température [38, 20, 75]. Le minimum obtenu par cette procédure d'optimisation permet ensuite de classer l'objet détecté comme faisant partie ou non de la classe d'objet considérée *a priori*. Le cadre de modélisation retenu et les solutions algorithmiques introduites ici sont suffisamment générales pour s'appliquer à une large classe de déformations et d'objets, permettant d'envisager son extension à d'autres applications en traitement des formes. Nous avons illustré cette partie avec de nombreux résultats expérimentaux, attestant la validité et l'intérêt de la

méthode proposée. En particulier, les résultats montrent que cette technique reste efficace lorsque l'ombre portée, que l'on cherche à classer, est partiellement occultée par l'ombre portée d'autres objets comme des cailloux ou des rides de sable. Dans ces cas, l'énergie finale après minimisation est un peu plus élevée que celle obtenue sans occultation, mais reste assez significative, c'est-à-dire assez faible pour un objet appartenant à la classe d'objet considérée et assez élevée dans le cas contraire, pour rendre une classification adéquate. Néanmoins, dans la perspectives de consolider cette phase d'identification des ombres portées, l'information sur la nature du fond marin peut se révéler utile. Ceci a fait l'objet de la dernière partie de ce mémoire.

- Dans la quatrième partie, nous avons proposé en effet un modèle statistique global pour la segmentation et la classification des fonds marins en imagerie SONAR. L'approche originale adoptée s'appuie sur une analyse des formes d'ombres que produit chaque type de fond. Un modèle markovien permet de spécifier, d'une part, les propriétés d'homogénéité de la carte de segmentation recherchée, et d'autre part d'exprimer la vraisemblance des observations par un module de décision floue. Dans ce cadre, le problème de la segmentation d'une image SONAR et de la classification des fonds marins est équivalent à un problème d'estimation bayésienne et conduit à la minimisation d'une fonction d'énergie, résolue par un algorithme de relaxation déterministe. Les résultats obtenus sur des images SONAR réelles présentant des fonds marins de toute nature, mettent en avant la pertinence de l'approche proposée [76].

Divers aspects de ce travail méritent sans doute d'être approfondis, offrant ainsi de nouvelles perspectives :

- ▷ Une estimation non supervisée du système de voisinage optimal. Pour certaines images SONAR, notamment celles pour lesquelles le champ d'étiquettes ne présente aucune directivité, un système de voisinage 4-connexe peut être suffisant. Cela permettrait de réduire sensiblement le temps de calcul nécessaire à l'estimation des paramètres et à l'étape de segmentation.
- ▷ La parallélisation des différents algorithmes et l'implantation du code sur des processeurs DSP permettraient de réduire sensiblement les temps de calcul et d'envisager des applications s'approchant du temps réel.
- ▷ La convergence du modèle MCE n'a pas été démontrée et reste un problème ouvert.

Les autres extensions possibles de ce travail sont essentiellement applicatives.

- ▷ Le cadre de modélisation utilisé pour la classification des ombres portées est suffisamment général pour s'appliquer à une large gamme de modèles statistiques. On pourrait ainsi utiliser l'approche proposée pour détecter les ombres portées de mines coniques (mines "manta"), de mines à orin ou pour d'autres objets dont l'ombre portée est plus complexe.
- ▷ Enfin, une segmentation en trois classes peut être utilisée dans l'optique d'une reconstruction 3D des objets posés sur le fond marin. Une séquence d'images de l'objet sous différents angles, segmentées en trois classes (*ombre/réverbération de fond/écho*), pourrait être exploitée pour une reconstruction 3D de cet objet. A cette fin, des méthodes de reconstruction 3D [108], utilisant un modèle *a priori* et une stratégie bayésienne existent.

Publications effectuées

JOURNAUX

- [1] C. Collet, P. Thourel, M. Mignotte, P. Bouthemy, P. Pérez. “Une nouvelle approche en traitement d’images sonar haute résolution : la segmentation markovienne hiérarchique multimodèle”. *Traitement du Signal*, accepté pour publication.
- [2] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. “Sonar image segmentation using an unsupervised hierarchical MRF model”. *IEEE Trans. on Image Processing*, **soumis**.
- [3] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. “Three-class Markovian segmentation of high resolution sonar images”. *CVGIP: Image Understanding*, **soumis**.
- [4] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. “Hybrid genetic optimization and statistical model-based approach for the classification of shadow shapes in sonar imagery”. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, **soumis**.
- [5] P. Galerne M. Mignotte, K.C. Yao, C. Collet, G. Burel “Unsupervised segmentation using a Kohonen SOM and a noise model estimation in sonar imagery”. *Pattern Recognition*, **soumis**.
- [6] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. ”Seafloor classification using Markov random field and fuzzy logic”. *IEEE Trans. on Journal of oceanic engenieering*, **soumis**.

CONFÉRENCES

- [1] F. Schmitt, M. Mignotte, C. Collet, P. Thourel. “Estimation of noise parameters on sonar images”. In: *Conf. Signal and Image Processing*, volume SPIE 2823, pages 1–12, Denver, Colorado, USA, août. 1996.
- [2] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. “Unsupervised Markovian segmentation of sonar images”. In: *22nd IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume 4, pages 2781–2785, Munich, mai 1997.
- [3] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. “Unsupervised segmentation applied on sonar images”. In: *Proc. International Workshop EMMCVPR’97: Energy Minimisation Methods in Computer Vision and Pattern Recognition*, volume LNCS 1223, pages 491–506, Venise, mai 1997. Springer-Verlag.
- [4] M. Mignotte, C. Collet, P. Pérez, P. Bouthemy. “Unsupervised hierarchical Markovian segmentation of sonar images”. In: *4th IEEE International Conference on Image Processing*, Santa Barbara, CA, oct. 1997.
- [5] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. “Statistical model and genetic optimization : application to pattern detection in sonar images”. In: *23th IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume V, pages 2741–2745, Seattle, mai 1998.

RAPPORTS DE RECHERCHE

- [1] M. Mignotte. Modèle markovien: Estimation des paramètres. Rapport technique 7, GTS, Ecole Navale, mars 1996.
- [2] M. Mignotte. Segmentation d'images sonar : modèle hiérarchique proposé. Rapport technique 14, GTS, Ecole Navale, déc 1996.
- [3] M. Mignotte. Segmentation trois classes et modélisation du bruit par lois de Weibull en imagerie sonar. Rapport technique 23, GTS, Ecole Navale, juin 1997.
- [4] M. Mignotte. Classification d'ombres portées en imagerie sonar par modèle statistique et algorithme génétique hybride. Rapport technique 28, GTS, Ecole Navale, oct 1998.

Bibliographie

- [1] D. Alexandrou and D. Pantzartzis. Seafloor classification with neural networks. In *IEEE Proc. OCEANS*, pages 18–23, 1990.
- [2] D. Alexandrou and D. Pantzartzis. A methodology for acoustic seafloor classification. *IEEE Journal of Oceanic Engineering*, 18(2):81–86, 1993.
- [3] G. V. April. Speckle statistics in four-look synthetic aperture radar imagery. *Optical Engineering*, 30(4):375–381, 1991.
- [4] S. Banks. *Signal processing, image processing and pattern recognition*. Prentice Hall, 1990.
- [5] M. G. Bello. A combined Markov random field and wave-packet transform-based approach for image segmentation. *IEEE Trans. on Image Processing*, 3(6):834–846, 1994.
- [6] J. Besag. Statistical analysis of non-lattice data. *The Statistician*, 24:179–195, 1977.
- [7] J. Besag. On the statistical analysis of dirty pictures. *Journal of the Royal Statistical Society, B*, 48:259–302, 1986.
- [8] J. M. Bordier, M. Fink, A. Le Bru, and F. Cohen Tenoudji. The influence of multiple scattering in incoherent ultrasonic inspection of coarse grain stainless steel. In *IEEE Proc. Ultrasonics Symposium*, volume 2, pages 803–808, Orlando, FL, USA, déc. 1991.
- [9] B. Bouchon-Meunier. *La logique floue et ses applications*. Addison-Wesley France, 1995.
- [10] C.A. Bouman and M. Shapiro. A multiscale random field model for Bayesian image segmentation. *IEEE Trans. on Image Processing*, 3(2):162–177, 1994.
- [11] B. Bourgeois and C. Walker. Sidescan sonar image interpretation with neural networks. In *IEEE Proc. OCEANS*, volume 3, pages 1687–1694, 1991.
- [12] M. Bouvet. *Traitement des Signaux pour les Systèmes Sonar*. Collection Technique et Scientifique des Télécommunications. Masson, Paris, 1992.
- [13] B. Braathen, P. Masson, and W. Pieczynski. Global and local methods of unsupervised Bayesian segmentation of images. *Graphics and Vision*, (1):39–52, 1993.
- [14] F. Brouaye. Estimation of mixing distributions. Application to classification problem in signal processing. Technical report, SUPELEC, 1990.
- [15] C. B. Burckhardt. Speckle in ultrasound B-Mode scans. *IEEE Trans. on Sonics and Ultrasonics*, SU-25(1):1–6, 1978.
- [16] D.R. Carmichael, L.M. Linnet, S.J. Clarke, and B.R. Calder. Seabed classification through multifractal analysis of sidescan sonar imagery. *IEE Proc. Radar, Sonar Navig.*, 143(3):140–148, 1996.
- [17] G. Celeux and J. Diebolt. L’algorithme SEM: un algorithme d’apprentissage probabiliste pour la reconnaissance de mélange de densités. *Revue de statistiques appliquées*, 34(2):35–52, 1986.

- [18] B. Chalmond. An iterative Gibbsian technique for reconstruction of m -ary images. *Pattern Recognition*, 22(6):747–761, 1989.
- [19] R. Chellapa. Time series models for multiresolution images. *Multiresolution Image Processing and Analysis*, pages 102–108, 1984.
- [20] D.T. Cobra and H.A de Moraes. Classification of side-scan sonar images through parametric modeling. In *Proc. OCEANS*, volume 2, pages 461–464, Brest, France, sept. 1994.
- [21] C. Collet, P. Thourel, P. Bouthemy, and P. Pérez. Détection d’ombres sur images sonar par une analyse multirésolution et une modélisation markovienne. In *15ème Colloque sur le Traitement du Signal et des Images (GRETSI)*, pages 569–572, Juan-Les-Pins, sept. 1995.
- [22] C. Collet, P. Thourel, M. Mignotte, P. Bouthemy, and P. Pérez. Une nouvelle approche en traitement d’images sonar haute résolution : la segmentation markovienne hiérarchique multimodèle. *Traitement du Signal, accepté pour publication*.
- [23] C. Collet, P. Thourel, P. Pérez, and P. Bouthemy. Hierarchical MRF modeling for sonar picture segmentation. In *International Conference on Image Processing - ICIP’96*, volume 3, pages 979–982, Lausanne, September 1996.
- [24] C. Collet, P. Thourel, P. Pérez, and P. Bouthemy. Sonar picture segmentation using markovian multigrid or multiresolution algorithms. In *Electronic Imaging: Sciences and Technology EI’97 - SPIE’s 9th Annual Symposium*, volume 3026, pages 221–232, San Jose, CA, February 1997.
- [25] E. Conte, M. Lops, and G. Ricci. Optimised radar detection in correlated Weibull clutter. In *14th colloque GRETSI*, pages 161–164, Juan-les-Pins, France, sept. 1993.
- [26] J.A Cornell. *Experiments with mixtures: designs models and the analysis of mixture data*. Wiley Interscience Publication, 1990.
- [27] G. R. Cross and A. K. Jain. Markov random field texture models. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 5(1):25–39, 1983.
- [28] J.P. Delmas. Relations entre les algorithmes d’estimation itérative EM et ICE avec exemples d’applications. In *15th colloque GRETSI*, pages 185–188, 1995.
- [29] A.P. Dempster, N.M. Laird, and D.B. Rubin. Maximum likelihood from incomplete data via the EM algorithm. *Royal Statistical Society*, pages 1–38, 1976.
- [30] H. Derin and H. Elliot. Modeling and segmentation of noisy and textured images using Gibbs random fields. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 9(1):39–55, 1987.
- [31] H. Derin, P. A. Kelly, and K. D. Hartt. Unsupervised segmentation of speckled images. In *IEEE Proc. of IGARSS*, pages 1349–1356, Ann Arbor, mai 1987.
- [32] P. Galerne. Classification d’ombre en imagerie sonar. Rapport technique 8, Ecole Navale, GTS, avr. 1996.
- [33] P. Galerne, M. Mignotte, K.C. Yao, C. Collet, and G. Burel. Unsupervised segmentation using a Kohonen SOM and a noise model estimation in sonar imagery. *Pattern Recognition, soumis*.
- [34] P. Galerne, K. Yao, and G. Burel. Object classification using neural network in sonar imagery. In *Proc. European Symposium on Lasers and Optics in Manufacturing*, pages 306–311, Munich, juin 1997.
- [35] D. Geiger and J.E. Kogler. Scaling images and image features via the renormalization group. In *IEEE Proc. Computer Vision and Pattern Recognition*, pages 47–53, juin 1993.
- [36] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 6(6):721–741, 1984.

- [37] B. Gidas. A renormalization group approach to image processing problem. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 11(2):164–180, 1989.
- [38] D.E Goldberg. *Genetic Algorithm*. Addison Wesley, 1989.
- [39] J. W. Goodman. Some fundamental properties of speckle. *Journal of Optical Society of America*, 66(11):1145–1150, 1976.
- [40] J. W. Goodman. A random walk through the field of speckle. *Optical Engineering*, 25(5):610–612, 1986.
- [41] C. Graffigne, F. Heitz, P. Pérez, F. Prêteux, M. Sigelle, and J. Zerubia. Hierarchical Markov random field models applied to image analysis: a review. In *SPIE Neural Morphological and Stochastic Methods in Image and Signal Processing*, volume 2568, pages 2–17, San Diego, juil. 1995.
- [42] U. Grenander and M. Keenan. Towards automated image understanding. *Advances in Applied Statistics*, 16:89–103, 1993.
- [43] F. Heitz. Champs markoviens et analyse statistique de l'image: fondements et applications. Tutorial, déc. 1991. IRISA/INRIA-Rennes.
- [44] F. Heitz, P. Pérez, and P. Bouthemy. Multiscale minimisation of global energy functions in some visual recovery problems. *CVGIP: Image Understanding*, 59(1):125–134, 1994.
- [45] F. Heitz, F. Preteux, C. Graffigne, M. Sigelle, and J. Zerubia. Modèles markoviens hiérarchiques pour l'analyse d'images. In *GDR Traitement du signal et des images*, CNRS département SPI, 1994.
- [46] I. Herlin, D. Bereziat, G. Giraudon, C. Nguyen, and C. Graffigne. Segmentation of echocardiographic images with Markov random fields. In *IEEE Proc. of Third European Conference on Computer Vision*, volume II, pages 201–206, Stockholm, Suède, mai 1994.
- [47] I. L. Herlin, C. Nguyen, and C. Graffigne. Stochastic segmentation of ultrasound images. In *Proc. of 11th IAPR International Conference on Pattern Recognition*, pages 289–292, La Haye, sept. 1992.
- [48] J. C. Hyland and G. J. Dobeck. Sea mine detection and classification using side-looking sonar. In *SPIE Detection Technologies for Mines and Minelike Targets*, volume 2496, pages 442–453, Orlando, Florida, avr. 1995.
- [49] A.K. Jain, Y. Zhong, and Sridhar Lakshmanan. Object matching using deformable templates. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 18(3):267–278, 1996.
- [50] F. Ching Jeng. Subsampling of Markov random fields. *Journal of Visual Communication and Image Representation*, 3(3):225–229, 1992.
- [51] M. Jiang, W. K. Stewart, and M. Marra. Segmentation of seafloor sidescan imagery using Markov random fields and neural networks. In *IEEE Proc. OCEANS*, volume 3, pages 456–461, Victoria, BC, Canada, oct. 1993.
- [52] M.P Dubuisson Jolly, Sridhar Lakshmanan, and A.K Jain. Vehicle segmentation and classification using deformable templates. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 18(3):293–308, 1996.
- [53] Z. Kato. *Modélisations markoviennes multirésolutions en vision par ordinateur. Application à la segmentation d'images SPOT*. Thèse de doctorat, Université de Nice, Inria Sophia-Antipolis, déc. 1994.
- [54] Z. Kato, M. Berthod, and J. Zerubia. A hierarchical Markov random field model and multi-temperature annealing for parallel image classification. Rapport de recherche numéro 1938, INRIA - Sophia Antipolis, août 1993.

- [55] Z. Kato, M. Berthod, and J. Zerubia. Multiscale Markov random field models for parallel image classification. In *IEEE Proc. International Conference on Computer Vision*, pages 253–257, Berlin, mai 1993.
- [56] Z. Kato, J. Zerubia, and M. Berthod. Unsupervised parallel image classification using a hierarchical Markovian model. In *IEEE Proc. International Conference on Computer Vision*, volume 1, pages 169–174, Cambridge, Massachusetts, juin 1995.
- [57] Z. Kato, J. Zerubia, M. Berthod, and W. Pieczynski. Unsupervised adaptative image segmentation. In *IEEE Proc. International Conference on Acoustics, Speech, and Signal Processing*, volume 4 of 5, pages 2399–2402, Detroit, USA, mai 1995.
- [58] C. Kervrann and F. Heitz. Statistical model-based segmentation of deformable motion. In *3rd IEEE Proc. International Conference on Image Processing*, pages 937–940, Lausanne, sept. 1996.
- [59] K. Kluge and S. Lakshmanan. Lane boundary detection using deformable templates: effects of image subsampling on detected lane edges. In *Proc. Asian Conference on Computer Vision*, pages 141–145, Singapour, déc. 1995.
- [60] I. Koren, A. F. Laine, J. Fan, and F. J. Taylor. Edge detection in echocardiographic image sequences by 3-D multiscale analysis. In *IEEE 1st International Conference on Image Processing*, pages 288–292, Austin, Texas, nov. 1994.
- [61] D. T. Kuan, A. A. Sawchuk, T. C. Strand, and P. Chavel. Adaptive restoration of images with speckle. In *SPIE - Applications of Digital Image Processing IV*, volume 359, pages 28–38, 1982.
- [62] J-M. Laferté, F. Heitz, P. Pérez, and E. Fabre. Fusion d’images multirésolutions par modèles markoviens hiérarchiques. In *15ème Colloque sur le Traitement du Signal et des Images (GRETSI)*, volume 2, pages 913–916, sept. 1995.
- [63] S. Lakshmanan and H. Derin. Simultaneous parameter estimation and segmentation of Gibbs random fields using simulated annealing. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 11(8):799–813, 1989.
- [64] S. Lakshmanan and D. Grimmer. A deformable template approach to detecting straight edges in radar images. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 18(4):438–443, 1996.
- [65] J. D. Lathrop. High area rate reconnaissance (HARR) and mine reconnaissance/hunter (MR/H) exploratory development. In *SPIE Detection Technologies for Mines and Minelike Targets*, volume 2496, pages 350–356, Orlando, FL, USA, avr. 1995.
- [66] J. S. Lee. Statistical modelling and suppression of speckle in synthetic aperture radar images. In *IEEE Proc. of IGARSS*, pages 1331–1339, Ann Arbor, mai 1987.
- [67] J. S. Lee and I. Jurkevich. Segmentation of SAR images. *IEEE Trans. on Geoscience and Remote Sensing*, 27-6:674–680, 1989.
- [68] K.Y Lim and H.S. Yang. A new hierarchical MRF modeling for image segmentation and restoration. In *Second Asian Conference on Computer Vision ACCV*, volume 1, pages 189–193, déc. 1995.
- [69] J. Marroquin, S. Mitter, and T. Poggio. Probabilistic solution of ill-posed problems in computation vision. *Journal of the American Statistical Association*, 82(397):76–89, 1987.
- [70] P. Masson and W. Pieczynski. SEM algorithm and unsupervised statistical segmentation of satellite images. *IEEE Trans. on Geoscience and Remote Sensing*, 31(3):618–633, 1993.
- [71] I. Matsuba. Renormalization group approach to hierarchical image analysis. In *IEEE Proc. International Conference on Acoustics, Speech, and Signal Processing*, pages 1044–1047, 1988.

- [72] M. Mignotte. Modèle markovien: Estimation des paramètres. Rapport technique 7, Ecole Navale, GTS, mars 1996.
- [73] M. Mignotte. Segmentation d'images sonar : modèle hiérarchique proposé. Rapport technique 14, GTS, Ecole Navale, déc. 1996.
- [74] M. Mignotte. Segmentation trois classes et modélisation du bruit par lois de Weibull en imagerie sonar. Rapport technique 23, Ecole Navale, GTS, juin 1997.
- [75] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Hybrid genetic optimization and statistical model-based approach for the classification of shadow shapes in sonar imagery. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, soumis.
- [76] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Seafloor classification using Markov random field and fuzzy logic. *IEEE Trans. on Journal of Oceanic Engineering*, soumis.
- [77] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Sonar image segmentation using an unsupervised hierarchical MRF model. *IEEE Trans. on Image Processing*, soumis.
- [78] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Three-class Markovian segmentation of high resolution sonar images. *Computer Vision and Image Understanding*, soumis.
- [79] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Unsupervised hierarchical Markovian segmentation of sonar images. In *Proc. International Conference on Image Processing*, Santa Barbara, Californie, USA, oct. 1997.
- [80] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Unsupervised Markovian segmentation of sonar images. In *22nd IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume 4, pages 2781–2785, Munich, mai 1997.
- [81] M. Mignotte, C. Collet, P. Pérez, and P. Bouthemy. Unsupervised segmentation applied on sonar images. In *Proc. International Workshop EMMCVPR'97: Energy Minimisation Methods in Computer Vision and Pattern Recognition*, volume LNCS 1223, pages 491–506, Venise, mai 1997. Springer-Verlag.
- [82] Y. Nakazawa, T. Komatsu, and T. Saito. A robust object-specified active contour model for tracking smoothly deformable line-features and its application to outdoor moving image processing. In *IEEE Proc. International Conference on Image Processing*, pages 689–692, Lausanne, sept. 1996.
- [83] C. Olivier, P. Courtellemont, and Y. Lecourtier. Histogrammes et critères d'information en reconnaissance de formes. *AFCET-RFIA*, 1996.
- [84] P. Pérez. *Champs markoviens et analyse multirésolution de l'image: application à l'analyse du mouvement*. Thèse de doctorat, Université de Rennes 1, IRISA, juil. 1993.
- [85] P. Pérez and F. Heitz. Une approche multiéchelle à l'analyse d'images par champs markoviens. *Traitement du Signal*, 9(6):459–472.
- [86] W. Pieczynski. Champs de Markov cachés et Estimation Conditionnelle Itérative. *Revue Traitement du Signal*, 11(2):141–153, 1994.
- [87] J.G. Postaire and P.A. Vasseur. An approximate solution to normal mixture identification with application to unsupervised pattern classification. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, PAMI-3(2):163–179, 1981.
- [88] E. Pouliquen and X. Lurton. Identification de la nature du fond de la mer à l'aide de signaux d'écho-sondeurs : modélisation d'échos réverbérés par le fond. *Acta Acustica*, 2(2):113–126, 1994.
- [89] H. C. Quelle. *Segmentation bayésienne non supervisée en imagerie radar*. Thèse de doctorat, Université de Rennes 1, fevr. 1993.

- [90] C. Regazzoni, F. Arduini, and G. Vernazza. A multilevel GMRF-based approach to image segmentation and restoration. *Signal Processing*, 34(1):43–67, 1993.
- [91] F. Schmitt, M. Mignotte, C. Collet, and P. Thourel. Estimation of noise parameters on sonar images. In *Signal and Image Processing*, volume SPIE 2823, pages 1–12, Denver, Colorado, USA, août 1996.
- [92] P. M. Shankar and V. L. Newhouse. Specificity and sensitivity of lesion detection by spatial compounding of B-mode images. In *IEEE Trans. on Ultrasonics Symposium*, pages 821–824, Dallas, Texas., nov. 1984.
- [93] J. Sivakumar and J. Goutsias. Morphologically constrained markov random fields. In *4th IEEE International Conference on Image Processing*, Santa Barbara, Californie, USA, oct. 1997.
- [94] D. P. Skinner. Mine countermeasures (MCM) sensor technology drivers. In *SPIE Detection Technologies for Mines and Minelike Targets*, volume 2496, pages 608–613, Orlando, FL, USA, avr. 1995.
- [95] W.K Stewart, M. Jiang, and M. Marra. A neural network approach to classification of sidescan sonar imagery from a mid-ocean ridge area. *IEEE Proc. Journal of Oceanic Engineering*, 19(2):214–224, 1994.
- [96] S. Subramaniam, H. Barad, and A.B. Martinez. Seafloor characterization using texture. In *IEEE Proc. Southeastcon*, 1993.
- [97] H. Thomas, C. Collet, G. Burel, and K. Yao. Classification neuronale des fonds marins par modélisation autorégressive bidimensionnelle. In *Colloque GRETSI*, volume 2, pages 925–928, Grenoble, sept. 1997.
- [98] P. Thourel. *Segmentation d’images sonar par modélisation markovienne hiérarchique et analyse multirésolution*. Thèse de doctorat, Université de Bretagne Occidentale, juil. 1996.
- [99] P. Thourel, C. Collet, P. Bouthemy, and P. Pérez. Multiresolution analysis and MRF modeling applied to the segmentation of shadows in sonar pictures. In *Second Asian Conference on Computer Vision ACCV*, volume 2, pages 81–85, Singapore, déc. 1995.
- [100] D. Vray, P. Delachartre, N. Andrieux, and G. Gimenez. Bottom classification using information in the spectral domain and time-frequency domain. In *Proc. OCEANS*, volume 2, pages 659–664, Brest, France, sept. 1994.
- [101] R. F. Wagner, M. F. Insana, and D. G. Brown. Unified approach to the detection and classification of speckle texture in diagnostic ultrasound. *Optical Engineering*, 25(6):738–742, 1986.
- [102] R. F. Wagner, S. W. Smith, J. M. Sandrik, and H. Lopez. Statistics of speckle in ultrasound B-scans. *IEEE Trans. on Sonics and Ultrasonics*, 30(3):156–163, 1983.
- [103] C. Wu and P. Doerschuk. Tree approximation to Markov random fields. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 17(4):391–402, 1995.
- [104] T. Yamazaki, M.N. Shirazi, and H. Noda. Data-driven segmentation of degraded images based on Markov random field models. *Journal of the communications research laboratory*, pages 19–36, 1994.
- [105] L. Younes. Parametric inference for imperfectly observed Gibbsian fields. *Springer-Verlag Probability Theory and Related Fields* 82, pages 625–645, 1989.
- [106] L.A. Zadeh. Fuzzy sets as a basis for a theory of possibility. *Fuzzy sets and systems 1*, pages 3–28, 1978.
- [107] B. Zerr, E. Maillard, and D. Gueriot. Sea-floor classification by neural hybrid system. In *IEEE Proc. of OCEANS*, volume 2, pages 239–243, Brest, France, sept. 1994.
- [108] B. Zerr and B. Stage. Three-dimensional reconstruction of underwater objects from a sequence of sonar images. In *IEEE Proc. 3rd International Conference on Image Processing*, pages 927–930, Lausanne, sept. 1996.

- [109] J. Zerubia, Z. Kato, and M. Berthod. Multi-temperature annealing: a new approach for the energy-minimization of hierarchical Markov random field models. *IEEE Proc. International Conference on Pattern Recognition*, pages 520–522, 1994.
- [110] J. Zhang, J. Modestino, and D.A. Langan. Maximum-likelihood parameter estimation for unsupervised stochastic model-based image segmentation. *IEEE Trans. on Image Processing*, 3(4):404–420, 1994.
- [111] Y. Zhao, X. Zhuang, I. Atlas, and L. Anderson. Parameter estimation and restoration of noisy images using Gibbs distributions in hidden Markov models. *CVGIP*, pages 187–197, 1992.

Annexe A

Étude des estimateurs MV

A.1 Loi de Rayleigh : étude de l'estimateur MV $\hat{\alpha}_{MV}^2$

Moment d'ordre 1 Vérifions que l'estimateur $\hat{\alpha}^2$ possède de bonnes propriétés asymptotiques: on calcule la moyenne de l'estimateur pour s'assurer qu'il est non biaisé.

$$\begin{aligned} E[\hat{\alpha}^2] &= \frac{1}{2N} E\left[\sum_{i=1}^N \tilde{y}_i^2\right] \\ &= \frac{1}{2N} \sum_{i=1}^N \underbrace{E[\tilde{y}_i^2]}_{2\alpha^2} \\ &= \alpha^2 \end{aligned}$$

l'estimateur est **non biaisé**.

Moment d'ordre 2 Calculons la variance de l'estimateur $\text{VAR}[\hat{\alpha}_{MV}^2]$ et vérifions que l'estimateur trouvé est efficace. On rappelle que, dans le cas où la taille de l'échantillon est finie, $\text{VAR}[\hat{\alpha}_{MV}^2]$ ne peut descendre au dessous d'un certain seuil déterminé par l'inégalité de Cramer-Rao. Un estimateur dont $\text{VAR}[\hat{\alpha}^2]$ atteint cette borne inférieure est dit efficace. Cherchons à déterminer cette borne inférieure appelée $\text{VAR}_{\min}$. Par définition, nous avons:

$$\text{VAR}_{\min}[\hat{\alpha}^2] \triangleq \frac{1}{I(\alpha^2)}$$

avec $I(\alpha^2)$ représentant l'information de Fisher:

$$I(\alpha^2) = -E\left[\frac{\partial^2}{\partial \alpha^4} \ln P_{Y/\alpha^2}(y/\alpha^2)\right]$$

$$\begin{aligned} \text{or} \quad \ln P_{Y/\alpha^2}(y/\alpha^2) &= \sum_{i=1}^N \ln \tilde{y}_i - N \cdot \ln \alpha^2 - \frac{1}{2\alpha^2} \sum_{i=1}^N \tilde{y}_i^2 \\ \frac{\partial}{\partial \alpha^2} \ln P_{Y/\alpha^2}(y/\alpha^2) &= -\frac{N}{\alpha^2} + \frac{1}{2\alpha^4} \sum_{i=1}^N \tilde{y}_i^2 \end{aligned}$$

$$\frac{\partial^2}{\partial \alpha^4} \ln P_{Y/\alpha^2}(y/\alpha^2) = \frac{N}{\alpha^4} - \frac{1}{\alpha^6} \sum_{i=1}^N \tilde{y}_i^2$$

De ce fait:

$$\begin{aligned} I(\alpha^2) &= -\frac{N}{\alpha^4} + \frac{1}{\alpha^6} \sum_{i=1}^N \underbrace{E[\tilde{y}_i^2]}_{2\alpha^2} \\ &= \frac{N}{\alpha^4} \end{aligned}$$

La borne inférieure de Cramer-Rao est donnée par l'expression:

$$\text{VAR}[\hat{\alpha}^2]_{\min} = \frac{\alpha^4}{N}$$

On calcule la variance de l'estimateur et on vérifie que la variance trouvée est bien la borne inférieure de Cramer-Rao:

$$\begin{aligned} \text{VAR}[\hat{\alpha}_{MV}^2] &= \frac{1}{4N^2} \sum_{i=1}^N \text{VAR}[\tilde{y}_i^2] \\ &= \frac{1}{4N^2} \sum_{i=1}^N \left(\underbrace{E[\tilde{y}_i^4]}_{8\alpha^4} - \underbrace{(E[\tilde{y}_i^2])^2}_{2\alpha^2} \right) \\ &= \frac{\alpha^4}{N} \end{aligned}$$

l'estimateur est **efficace**. De plus:

$$\lim_{N \rightarrow \infty} \left(\text{VAR}[\hat{\alpha}_{MV}^2] \right) = 0$$

qui nous montre que l'estimateur $\hat{\alpha}_{MV}^2$ est aussi **consistant**.

A.2 Loi de Weibull : étude de l'estimateur MV $\hat{\alpha}_{MV}^C$

Moment d'ordre 1 :

$$\begin{aligned} E[\hat{\alpha}^{\hat{C}}] &= E\left[\frac{1}{N} \sum_{i=1}^N \tilde{y}_i^{\hat{C}}\right] \\ &= \frac{1}{N} \sum_{i=1}^N \underbrace{E[\tilde{y}_i^{\hat{C}}]}_{\alpha^C} \\ &= \alpha^C \end{aligned}$$

L'estimateur est **non biaisé**.

Moment d'ordre 2 : Par définition, la BICR s'écrit:

$$\text{VAR}_{\min}[\hat{\alpha}^C] \triangleq \frac{1}{I(\alpha^C)}$$

avec $I(\alpha^C)$ représentant l'information de Fisher:

$$I(\alpha^C) = -E \left[\frac{\partial^2}{\partial \alpha^{2C}} \ln P_{Y/\alpha^C}(y/\alpha^C) \right]$$

$$\begin{aligned} \text{or} \quad \ln P_{Y/\alpha^C}(y/\alpha^C) &= N \ln C + (C-1) \sum_{i=1}^N \ln \tilde{y}_i - NC \ln \alpha - \frac{1}{\alpha^C} \sum_{i=1}^N \tilde{y}_i^C \\ \frac{\partial}{\partial \alpha^C} \ln P_{Y/\alpha^C}(y/\alpha^C) &= -\frac{N}{\alpha^C} + \frac{1}{\alpha^{2C}} \sum_{i=1}^N \tilde{y}_i^C \\ \frac{\partial^2}{\partial \alpha^{2C}} \ln P_{Y/\alpha^C}(y/\alpha^C) &= \frac{N}{\alpha^{2C}} - \frac{2}{\alpha^{3C}} \sum_{i=1}^N \tilde{y}_i^C \end{aligned}$$

De ce fait:

$$\begin{aligned} I(\alpha^C) &= -E \left[\frac{\partial^2}{\partial \alpha^{2C}} \ln P_{Y/\alpha^C}(y/\alpha^C) \right] \\ &= -\frac{N}{\alpha^{2C}} + \frac{2}{\alpha^{3C}} \sum_{i=1}^N \underbrace{E[\tilde{y}_i^C]}_{\alpha^C} \\ &= \frac{N}{\alpha^{2C}} \end{aligned}$$

La borne inférieure de Cramer-Rao est donc donnée par l'expression suivante:

$$\text{VAR}[\hat{\alpha}^C]_{\min} = \frac{\alpha^{2C}}{N}$$

On calcule la variance de l'estimateur et on vérifie que la variance trouvée est bien la borne inférieure de Cramer-Rao:

$$\begin{aligned} \text{VAR}[\hat{\alpha}_{MV}^C] &= \text{VAR} \left[\frac{1}{N} \sum_{i=1}^N \tilde{y}_i^C \right] \\ &= E \left[\left(\frac{1}{N} \sum_{i=1}^N \tilde{y}_i^C - \alpha^C \right) \left(\frac{1}{N} \sum_{i=1}^N \tilde{y}_i^C - \alpha^C \right) \right] \\ &= \frac{1}{N^2} E \left[\sum_{i=1}^N \tilde{y}_i^C \sum_{j=1}^N \tilde{y}_j^C \right] - \frac{2\alpha^C}{N} E \left[\sum_{i=1}^N \tilde{y}_i^C \right] + \alpha^{2C} \\ &= \frac{1}{N^2} \left[N \underbrace{E[\tilde{y}_i^{2C}]}_{2\alpha^{2C}} + (N^2 - N) \underbrace{E[\tilde{y}_i^C]}_{\alpha^C} \right] - \frac{2\alpha^C}{N} N\alpha^C + \alpha^{2C} \\ &= \frac{\alpha^{2C}}{N} \end{aligned}$$

L'estimateur est **efficace**. De plus:

$$\lim_{N \rightarrow \infty} \left(\text{VAR}[\hat{\alpha}_{MV}^C] \right) = 0$$

qui nous montre que l'estimateur $\hat{\alpha}_{MV}$ est aussi **consistant**.

Annexe B

Test du χ^2 et distance de Kolmogorov

Nous présentons ici deux tests classiques utilisés pour juger de la ressemblance d’une loi empirique (dans notre application, cette loi est l’histogramme de l’image) à une loi théorique supposée adéquate (ou loi estimée pour notre application).

Le test du χ^2

Soit une variable aléatoire W à valeurs dans $\{w_0, \dots, w_r\}$ et n observations à valeur dans le même ensemble. Si k_l est le nombre de fois où l’état w_l apparaît dans ce n -échantillon, alors $k_0 + \dots + k_r = n$ et la fréquence empirique de l’état w_l est k_l/n . Si les échantillons sont effectivement issus de la v.a. W , alors ces fréquences doivent se rapprocher des probabilités $P_l \triangleq P_W(w_l)$, et on peut montrer que :

$$\underbrace{\sum_{l=0}^r \frac{(k_l - nP_l)^2}{nP_l}}_{d^2} \xrightarrow{n \rightarrow \infty} \chi_r^2$$

Pour n grand, l’hypothèse de modélisation de l’échantillon par la loi P_W sera rejetée si la “distance” d^2 a une valeur qui n’a qu’une faible probabilité d’être dépassée par une variable χ^2 [26, 83] à r degrés de libertés.

Distance de Kolmogorov

On peut définir d’autres mesures de distance. La plus simple est la distance variationnelle de Kolmogorov [26, 83]. Si on utilise les mêmes notations que précédemment, elle s’exprime comme suit:

$$\mathcal{K} = \sum_{l=0}^r |k_l - nP_l|$$

Annexe C

Pyramides de données utilisées dans l'algorithme RMR

Les mosaïques ci-dessous représentent les pyramides de données, obtenues à partir des observations initiales, qui seront exploitées par l'algorithme RMR (Relaxation MultiRésolution). Une pyramide est construite par adoucissement quaternaire et décimation d'ordre deux, ou par convolution par une porte de largeur deux pixels et sous échantillonnage d'ordre deux.

Pyramides multirésolution d'images SONAR




FIG. C.1 – *Exemples de pyramides multirésolutions d'images SONAR.*

Annexe D

USIS

Le logiciel USIS¹ représente près de 15000 lignes de code écrites en C++ sous UNIX (Système AIX version 4.1) et X-Window (version X11R5). Le programme a été écrit selon une conception orientée objet et une approche client/serveur. Il se répartit en trente classes (dont deux abstraites) et près de trois cents fonctions membres (ou méthodes), et une douzaine de fonctions amies. L'IHM² utilisée pour l'interfacer graphiquement a été écrite sous MOTIF 1.2.

La figure D.2 présente l'architecture utilisée selon la méthode OOA³. Les différentes classes sont représentées par un ovale et celles qui sont en pointillés représentent les classes abstraites. Les flèches épaisses symbolisent les relations d'héritage, et les flèches fines les liens d'utilisation.

USIS permet interactivement, à travers son interface graphique, de choisir une des méthodes d'estimation de paramètres ou de segmentation d'image présentées et testées en partie I et II de ce document. Il propose ainsi près de dix-huit algorithmes de segmentation non supervisée différents s'appuyant sur une approche markovienne. L'IHM comprend, un menu déroulant (*pop-up menu*) pour sélectionner la méthode d'initialisation/estimation/segmentation et le fichier à traiter, une boîte à listes (*list-box*) pour sélectionner le type de modèle de bruit, un ensemble de boîtes à cocher (*check boxes*) pour les différentes options, et des boutons poussoirs (*push buttons*), ainsi qu'un répertoire (*notebook*) et un fichier d'aide.




FIG. D.1 – IHM de l'application USIS.

-
1. Unsupervised Segmentation of Image Sonar
 2. Interface Homme Machine
 3. Oriented Object Analysis

Graphe d'héritage de l'application USIS




FIG. D.2 – Graphe d'héritage des différentes classes de l'application USIS.

Annexe E

SMACOSS

Le programme SMACOSS¹ représente près de 12000 lignes de code écrites en C++ sous UNIX (système AIX version 4.1) et X-Window (version X11R5). Le programme a été écrit selon une conception orientée objet et une approche client/serveur. Il se répartit en dix classes (dont une abstraite) et près de cent cinquante fonctions membres (ou méthodes) et une douzaine de fonctions amies. L'IHM² utilisée pour l'interfacer graphiquement a été écrite sous MOTIF 1.2.

La figure E.2 représente l'architecture utilisée selon la méthode OOA³. Les différentes classes sont représentées par un oval (celles qui sont en pointillés représentent les classes abstraites). Les flèches épaisses symbolisent les relations d'héritage et les flèches fines représentent les liens d'utilisation.

SMACOSS permet interactivement, grâce à son interface graphique, de choisir, l'image SONAR à traiter, le modèle recherché (modèle d'ombre portée cylindrique ou sphérique) ainsi que l'une des trois méthodes d'optimisation présentées et testées. L'IHM comprend entre autre, un menu déroulant (*pop-up menu*) pour la sélection du fichier, du modèle, et la méthode d'optimisation, un ensemble de boîtes à cocher (*check boxes*) et des boutons poussoirs (*puch buttons*) pour les différentes options et trois ascenseurs (*sliders*) pour la sélection des paramètres de contrôle de l'AG (cf. fig. E.2).




FIG. E.1 – IHM de l'application SMACOSS.

1. Statistical Model Approach for the Classification of Shadow Shape
2. Interface Homme Machine
3. Oriented Object Analysis

Graphe d'héritage de l'application SMACOSS




FIG. E.2 – Graphe d'héritage des différentes classes de l'application SMACOSS.

Classes utilisées

Classes abstraites	
ga	Algorithme génétique.
Classes concrètes	
model	Modèle d'ombre portée cylindrique.
model2	Modèle d'ombre portée sphérique.
imagefield	Algorithme de calcul du potentiel de contour.
sa-model	Optimisation de Model par l'algorithme du <i>recuit simulé</i> .
de-model	Optimisation de Model par l'algorithme du gradient.
ga-model	Optimisation de Model par algorithme génétique.
ga-model2	Optimisation de Model2 par algorithme génétique.

TAB. E.1 – Tableau des différentes classes de l'application SMACOSS.



Résumé

Le SONAR haute résolution constitue un moyen efficace pour observer la très grande variété d'objets reposant sur les fonds marins. Ces dernières années, de nombreuses améliorations ont rendu ces SONAR de plus en plus performants (zones explorées plus vastes, visualisation des résultats sous forme d'images . . .). En contre partie, la quantité d'informations a sensiblement augmentée et rend aujourd'hui nécessaire d'automatiser la détection et la classification de ces objets. Celle-ci est réalisée grâce à une analyse de la forme de l'ombre que produise ces objets sur les images SONAR. L'automatisation de la phase de classification requiert donc une première étape de segmentation. A cette fin, un modèle de segmentation intégrant des interactions à la fois spatiales et causales en échelle et utilisant une stratégie de minimisation multigrille a été défini. Le problème de l'estimation automatique des paramètres de ce modèle a été développé dans le but de définir une segmentation non supervisée. Il comporte l'identification du mélange de lois relatif au terme d'attache aux données et des paramètres de régularisation contextuelle du modèle markovien. Nous avons ensuite proposé une méthode de classification des ombres portées détectées lors de la phase de segmentation. L'approche que nous avons adoptée utilise les modèles statistiques et repose sur une formulation bayésienne du problème. Elle comprend la définition d'une forme prototype à laquelle est appliquée une combinaison de déformations géométriques linéaires. Dans ce cadre, le problème de la classification d'un objet est équivalent à un problème d'estimation bayésienne des paramètres de déformation du modèle. Cette estimation conduit à la minimisation d'une fonction d'énergie non linéaire réalisée, dans notre application, par une procédure d'optimisation génétique. Le minimum obtenu par cette procédure permet ensuite de classer l'objet détecté comme faisant partie ou non de la classe d'objet considérée *a priori*. Afin d'améliorer cette classification, un modèle statistique pour la classification des fonds en imagerie SONAR, utilisant une analyse des formes d'ombres que produit chaque type de fond et un module décision floue, a été parallèlement proposé. Ces différentes méthodes ont été validées sur des images SONAR synthétiques et de nombreuses images SONAR réelles.

Mots clefs : inférence bayésienne, segmentation d'images sonar, modélisation markovienne hiérarchique, estimation de paramètres, modèle statistique, classification d'ombres portées, algorithme génétique, logique floue, problèmes d'optimisation.

Abstract

Over the last decades, with significant advances in SONAR technology, sidescan SONAR have provided high-quality acoustic images of the sea-bed, allowing to detect object lying on the seabed. However, because of the large data amount to process, the exploitation of the collected data has now to be achieved with an automatic processing chain. The detection of objects located on the sea bottom and then their classification (as wrecks, rocks, man-made objects, and so on . . .) are based on the extraction and the identification of their associated cast shadows. Thus, before any classification step, one must segment the SONAR image between shadow and sea-bottom reverberation areas. To this end, we have defined a segmentation model integrating a scale-causal and spatial interactions and using a multigrid minimization strategy specifically well suited for the SONAR image segmentation problem. In order to make this segmentation unsupervised, we estimate both the parameters of the mixture-based data model and those of the prior MRF model in a parameter estimation step before the segmentation step. Then, we present a cast shadow classification method. The adopted approach uses statistical models and the Bayesian framework. In this way, we define a prototype template and a set of admissible linear transformations to take into account the shape variability of the object class to be detected. Then, the detection problem of an object class is stated in a Bayesian setting as the estimation of the deformation parameters of a prototype template. This estimation problem is equivalent to the minimization of a complex objective function. This energy function is efficiently minimized, in our application, with a genetic optimization procedure. The resulting value of energy allows to determine whether the desired object is present or not. In order to improve this classification task, a statistical model, based on the identification of the cast shadow shapes for each bottom type and a fuzzy classifier, has been proposed. These methods have been validated by experiments on synthetic and numerous real SONAR images.

Keyword : Bayesian inference, sonar image segmentation, hierarchical Markovian model, parameter estimation, statistical model, cast shadow shape classification, genetic algorithm, fuzzy logic, optimization problems