



**HAL**  
open science

# Traitement d'images et fusion de données pour la détection d'objets enfouis en acoustique sous-marine

Frederic Maussang

► **To cite this version:**

Frederic Maussang. Traitement d'images et fusion de données pour la détection d'objets enfouis en acoustique sous-marine. Traitement du signal et de l'image [eess.SP]. Université Joseph-Fourier - Grenoble I, 2005. Français. NNT: . tel-00011447

**HAL Id: tel-00011447**

**<https://theses.hal.science/tel-00011447>**

Submitted on 23 Jan 2006

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# UNIVERSITE JOSEPH FOURIER – GRENOBLE 1

N° attribué par la bibliothèque

---

## THESE

pour obtenir le grade de

DOCTEUR DE L'UNIVERSITE JOSEPH FOURIER – GRENOBLE 1

**Spécialité : «Signal, Image, Parole et Télécoms»**

préparée au Laboratoire des Images et des Signaux de Grenoble

dans le cadre de l'École Doctorale «**Électronique, Électrotechnique,  
Automatique, Télécommunications et Signal**»

présentée et soutenue publiquement

par

**Frédéric MAUSSANG**

né le 8 avril 1979, à Riom (Puy-de-Dôme)

le 30 novembre 2005

Titre :

**TRAITEMENT D'IMAGES ET FUSION DE DONNÉES  
POUR LA DÉTECTION D'OBJETS ENFOUIS  
EN ACOUSTIQUE SOUS-MARINE**

**Directeurs de thèse : Michèle ROMBAUT et Jocelyn CHANUSSOT**

## **JURY**

Madame	G. Jourdain,	Présidente
Monsieur	C. Collet,	Rapporteur
Monsieur	B. Jouvencel,	Rapporteur
Monsieur	A. Appriou,	Examineur
Madame	M. Rombaut,	Directrice de thèse
Monsieur	J. Chanussot,	Co-directeur de thèse
Monsieur	A. Hétet,	Invité



– *Ad augusta*  
– *Per angusta*<sup>1</sup>

**Victor Hugo**, *Hernani* (IV, 3)

---

<sup>1</sup> *Vers de grandes choses par des voies étroites* : cette locution latine apparaît comme le mot de passe des conjurés d'*Hernani*.



# Remerciements

Je tiens tout d'abord à remercier mes deux directeurs de thèse Madame Michèle Rombaut et Monsieur Jocelyn Chanussot pour leur compétence, leur disponibilité, leur écoute et la qualité de leur encadrement en général. Ils ont su me conseiller et me guider aux moments clés de ce travail de trois ans, tout en me laissant la liberté nécessaire à la réalisation de ce projet de longue alêne. Ils ont également su me remonter le moral à certains moments difficiles et m'ont permis de surpasser ma réserve naturelle afin de prendre confiance en moi-même. Ils m'ont enfin aidé à préparer mon avenir professionnel dans la recherche scientifique. De plus, certaines similitudes ont permis de me sentir plus proches d'eux. En effet, le début de ma thèse a concordé avec l'arrivée de Michèle Rombaut à Grenoble en tant que Professeur. De même, avec Jocelyn Chanussot, outre nos points communs concernant la densité capillaire, nos arrivées simultanées à l'ENSIEG (lui en tant que Maître de Conférence, moi en tant qu'étudiant) ont créé entre nous des liens solides.

Je remercie également l'ensemble des personnes qui m'ont fait l'honneur d'être membres du jury. Je pense tout d'abord à Madame Geneviève Jourdain, qui l'a présidé, et qui a utilisé ses grandes compétences, dont j'ai déjà eu l'occasion de bénéficier durant ma formation d'ingénieur, au service de l'évaluation de mon travail. Toute ma considération va également aux membres qui ont dû venir, parfois de très loin en train ou en avion, pour assister à ma soutenance. Je tiens ainsi à remercier les deux rapporteurs, Messieurs Christophe Collet et Bruno Jouvencel, qui ont eu le courage de lire attentivement mon manuscrit et en ont fait une critique très fine et constructive. Ma reconnaissance va également à Monsieur Alain Appriou qui a utilisé toute sa connaissance, en particulier dans le domaine du radar, dans l'examen attentif de mon travail. Merci enfin à Monsieur Alain Hétet pour ses remarques très pertinentes sur mon manuscrit et son examen, bref mais efficace, de ma présentation.

Je tiens également à remercier Monsieur Jean-Marc Chassery, directeur du LIS, pour m'avoir accueilli dans son laboratoire.

J'associe à mes remerciements le Groupe d'Etudes Sous-Marines de l'Atlantique de Brest avec qui s'est réalisé le travail. Je pense en particulier à Alain Hétet, que j'ai déjà cité plus haut, et à Mademoiselle Maud Amate, les deux ingénieurs d'étude avec qui nous avons entretenu une collaboration régulière et enrichissante. Je les remercie ainsi également pour leur accueil durant le séjour de deux mois que j'ai effectué auprès d'eux et qui m'a permis d'appliquer mes études sur de nouvelles données sonar et de confronter nos points de vue sur le problème posé.

Toute ma considération va également à Monsieur Jérôme Mars qui m'a accueilli au sein du groupe Signaux et Images en Milieu Naturel et, bien qu'il n'ait pas encadré ma thèse, a su me conseiller aux moments clés.

Je n'oublie certainement pas tous ceux sans qui mes trois années de thèse ne se seraient pas passées aussi bien. Je pense en particulier aux thésards et anciens thésards avec qui j'ai partagé de bons moments, ainsi que les repas du restaurant universitaire. J'ai une pensée toute particulière à François, Hakim, Christophe et Meryem qui ont successivement partagé avec moi le bureau des bannis qu'ils ont su égayer par leur présence. Je remercie également Sebastian qui, ayant commencé à rédiger sa thèse avant moi, m'a aidé à la rédaction de mon manuscrit en m'envoyant les fichiers modèles et en me donnant de précieux conseils. Le fait d'avoir rédigé, puis soutenu, à des moments très proches a créé entre nous des liens forts. Je pense également à Laurent, président de l'association MALIS que nous avons créée ensemble avec d'autres thésards, à Alejandro, Anthony, Antoine, Barbara, Benoît L., Benoît R., Brice, Caroline, Cédric, Corentin, Eric, Fabien, Franck, Gaël, Grégoire, Isabelle, Mathieu, Matthieu, Maxime, Mickaël, Moussa, Pierre, Sébastien, Vincent, Zakhia. . .

Toute ma considération va également aux deux stagiaires que j'ai encadrés durant ces années : Sofia qui est retournée en Roumanie pour finir ses études, Lionel qui a continué en thèse au LIS. Je les remercie pour tout ce qu'ils ont pu m'apporter autant du point de vue scientifique que de celui de l'expérience que j'ai acquise dans l'encadrement de projet. Des relations amicales sont également nées de ces stages et ont continué par la suite.

Mes remerciements vont également à ceux avec qui j'ai effectué mes enseignements : Jérôme, Jocelyn, Patrick, Pierre. . .

Je remercie également l'ensemble des personnes du service informatique, et en particulier Hervé et Jean-Marc, qui ont facilité mon travail grâce à leur compétence et leur professionnalisme.

Mes remerciements vont aussi à Christophe et Benoît, deux anciens collègues de promo de l'ENSIEG, qui m'ont fait l'honneur de prendre une journée de congé pour venir assister à ma présentation et m'apporter ainsi un soutien moral non négligeable.

Je remercie enfin mes parents pour leur soutien sans faille et ce jusqu'à ma soutenance pour laquelle ils ont fait le déplacement depuis Riom. Les séjours fréquents que j'ai effectués en Auvergne ont permis de puiser auprès d'eux l'énergie nécessaire à mon travail de thèse. Merci à ma mère pour sa lecture attentive du manuscrit qui a permis de l'améliorer grandement du point de vue orthographique et grammatical.

Je demande à ceux que j'ai pu oublier dans cette page de bien vouloir m'excuser, mais ils peuvent être sûrs qu'ils sont dans mes pensées.

# Table des matières

<b>1</b>	<b>Détection en acoustique sous-marine</b>	<b>9</b>
1.1	Introduction . . . . .	11
1.2	L'acoustique sous-marine : histoire et applications . . . . .	11
1.2.1	Histoire de l'acoustique sous-marine . . . . .	11
1.2.2	Principales applications civiles et militaires . . . . .	12
1.2.3	Application à la chasse aux mines sous-marines . . . . .	14
1.3	Imagerie sonar et détection sous-marine . . . . .	17
1.3.1	Les systèmes acoustiques imageurs . . . . .	17
1.3.2	Traitement des images sonar . . . . .	18
1.3.3	Détection d'objets . . . . .	22
1.4	Problème posé . . . . .	26
1.4.1	Données traitées . . . . .	26
1.4.2	Méthodes de détection proposées . . . . .	30
<b>2</b>	<b>Description statistique globale des images sonar</b>	<b>33</b>
2.1	Introduction . . . . .	35
2.2	Le bruit de speckle et la loi de Rayleigh . . . . .	35
2.2.1	Le bruit de speckle . . . . .	35
2.2.2	Loi de Rayleigh . . . . .	36
2.3	Modélisation par des lois non gaussiennes . . . . .	38
2.3.1	Loi de Weibull . . . . .	39
2.3.2	Lois K . . . . .	41
2.3.3	Autres modèles non gaussiens . . . . .	44
2.4	Comparaison des modèles statistiques . . . . .	45
2.4.1	Evaluations de la performance des modèles statistiques . . . . .	45
2.4.2	Comparaison sur les données SAS . . . . .	46
<b>3</b>	<b>Description statistique locale des images sonar</b>	<b>51</b>
3.1	Introduction . . . . .	53
3.2	Relation entre la moyenne et l'écart-type au niveau local . . . . .	53
3.2.1	Modélisation statistique des images sonar au niveau local . . . . .	53
3.2.2	Relation entre la moyenne et l'écart-type . . . . .	54
3.3	Représentation moyenne / écart-type . . . . .	56

3.3.1	Construction de la représentation moyenne/écart-type . . . . .	56
3.3.2	Interprétation de la représentation . . . . .	59
3.3.3	Liens avec l'image sonar . . . . .	60
3.4	Segmentation automatique des images sonar . . . . .	61
3.4.1	Principe de la méthode de segmentation . . . . .	61
3.4.2	Automatisation de la segmentation . . . . .	62
3.5	Application aux données SAS . . . . .	66
3.5.1	Evaluation des performances . . . . .	66
3.5.2	Segmentation des images SAS . . . . .	67
3.6	Bilan . . . . .	78
<b>4</b>	<b>Utilisation des statistiques d'ordres supérieurs</b>	<b>81</b>
4.1	Introduction . . . . .	83
4.2	Statistiques d'ordres supérieurs : définition et estimation . . . . .	83
4.2.1	Introduction aux SOS . . . . .	83
4.2.2	Définitions et propriétés . . . . .	84
4.2.3	Estimateurs . . . . .	86
4.3	Utilisation des statistiques d'ordres supérieurs pour la détection : cas gaussien	87
4.3.1	Propriétés locales des SOS . . . . .	87
4.3.2	Application à la détection de petits objets : cas des RSB faibles . .	90
4.3.3	Application à la détection de petits objets : cas des RSB élevés . .	94
4.3.4	Application à la détection de petits objets : cas des RSB intermédiaires	98
4.3.5	Détection avec un RSB élevé : focalisation et reconstruction de la région déterministe . . . . .	100
4.4	Utilisation des statistiques d'ordres supérieurs pour la détection : application aux images sonar . . . . .	105
4.4.1	Spécificités des images sonar . . . . .	106
4.4.2	Résultats et évaluation . . . . .	110
4.5	Conclusion sur l'utilisation des statistiques d'ordres supérieurs . . . . .	112
<b>5</b>	<b>Fusion des données</b>	<b>121</b>
5.1	Introduction . . . . .	123
5.2	Choix de la méthode de fusion . . . . .	123
5.2.1	Intérêt de la fusion de données . . . . .	123
5.2.2	Différentes méthodes de fusion et choix de la méthode . . . . .	126
5.2.3	Théorie de l'évidence . . . . .	127
5.3	Application à la détection en imagerie sonar . . . . .	130
5.3.1	Choix des paramètres et schéma de la fusion . . . . .	130
5.3.2	Choix des hypothèses et définition des fonctions de masse . . . . .	132
5.3.3	Evaluations de la performance de classification . . . . .	136
5.4	Résultats sur les données sonar . . . . .	139
5.4.1	Fusion des données sur les images SAS . . . . .	139
5.4.2	Représentation des résultats . . . . .	151

---

5.4.3	Utilisation d'autres paramètres . . . . .	155
5.5	Conclusion . . . . .	157
<b>Conclusion</b>		<b>159</b>
<b>A Filtrage des images sonar</b>		<b>161</b>
A.1	Introduction . . . . .	161
A.2	Filtres simples . . . . .	162
A.2.1	Filtre moyeneur . . . . .	162
A.2.2	Filtre moyeneur adaptatif . . . . .	163
A.2.3	Filtre à diffusion anisotrope . . . . .	164
A.2.4	Filtre médian . . . . .	165
A.3	Filtres adaptés au speckle . . . . .	166
A.3.1	Filtres homomorphiques . . . . .	166
A.3.2	Filtre de Lee . . . . .	167
A.4	Filtrage adaptatif . . . . .	168
<b>Liste des Publications</b>		<b>171</b>
<b>Bibliographie</b>		<b>173</b>
<b>Table des figures</b>		<b>181</b>
<b>Liste des tableaux</b>		<b>187</b>



# Introduction

Née au début du XX<sup>e</sup> siècle, la détection sous-marine a d'abord été utilisée à des fins stratégiques, notamment pour la lutte anti-sous-marine au cours de la Première Guerre Mondiale. On la retrouve actuellement à la fois dans des applications militaires (détection de sous-marins ou de mines sous-marines) et civiles (industrie de la pêche, cartographie, archéologie, recherche pétrolière, . . .).

Les ondes acoustiques se sont très vite imposées dans le domaine de la détection sous-marine pour leur pouvoir de propagation dans le milieu marin. En effet, la lumière se propage très difficilement dans un milieu aquatique, et il en est de même pour les ondes électromagnétiques en général. Ont donc été conçus des systèmes sonar, qui permettent d'émettre et recevoir des ondes acoustiques. Malgré leur directivité, plus mauvaise que pour un radar, les sonars permettent une bonne propagation de l'onde dans le milieu marin. Les plus récents permettent même d'imager les fonds marins, ce qui a fait progresser certaines applications, telles que la cartographie et la géologie, les images étant plus informatives pour l'oeil humain. De nouveaux systèmes acoustiques, tels que les Sonars à Antenne Synthétiques (SAS), sont apparus récemment fournissant des images de bonne résolution, avec des fréquences suffisamment basses pour pénétrer dans le sédiment marin (de l'ordre de la dizaine de kilohertz).

Mais, à l'instar de toute donnée issue d'ondes cohérentes, les images sonar présentent un aspect granulaire, dû au speckle, qui fait décroître sensiblement le rapport signal à bruit. Ceci complique fortement l'analyse de ces images. C'est pourquoi de nombreux travaux ont été réalisés sur leur interprétation, et notamment pour la détection et la localisation d'objets.

Dans le cas d'objets posés sur le fond (par exemple des mines sous-marines) la reconnaissance de leurs ombres projetées, qui ne sont pas touchées par le speckle, permet une classification efficace. De nombreux algorithmes ont été proposés dans ce sens : segmentation des ombres, identification, etc. Par contre, le cas des objets enfouis est plus complexe, car les ombres sont absentes, et a été plus rarement abordé. Les échos, (réflexion de forte intensité de l'onde sur les objets) sont alors les seules manifestations de la présence de ces objets. Ceci complique grandement la détection, les échos étant généralement de petite taille et d'amplitude peu différente de celle du fond.

Il semble alors intéressant de s'intéresser plus en détail à ce problème de détection

des objets enfouis grâce à leurs échos. Disposant d'une image sonar, formée de pixels, un processus de détection et de classification complet se décomposerait en trois étapes principales :

1. **au niveau du pixel** : la décision porte sur l'appartenance ou non d'un pixel à un objet ou au fond. Pour cela, nous pouvons étudier les propriétés statistiques dans le voisinage de chaque pixel afin de séparer les échos du fond bruité. Cette étape conduit à une segmentation des objets recherchés.
2. **au niveau de l'objet** : on détermine si l'objet segmenté est réel ou pas. On utilise pour cela des paramètres de forme (taille, . . .) et de position de l'objet.
3. **détermination du type d'objet** : on rentre dans un processus de classification et d'identification de l'objet. On détermine si l'objet est de type connu ou recherché, ou pas. On peut effectuer ensuite une comparaison avec des modèles d'objets afin de l'identifier.

Dans cette thèse, nous nous intéressons plus particulièrement à la première étape de ce processus. Pour cela, nous nous focalisons sur les propriétés statistiques des images sonar qui nous fournissent des connaissances approfondies pour une détection efficace des objets présents sur les images en utilisant leurs échos. Les algorithmes ainsi développés utilisent des outils de traitement d'images. Les résultats obtenus sont ensuite fusionnés pour avoir un processus de détection performant.

Cette thèse se décompose en cinq parties principales. Nous présentons tout d'abord, dans le chapitre 1, quelques généralités sur la détection en acoustique sous-marine et un état de l'art des traitements et algorithmes déjà proposés en imagerie sonar. A la fin du même chapitre, sont présentées les données sonar (SAS) sur lesquelles sont testées et évaluées les différentes méthodes de détection développées dans ce mémoire. Ces images contiennent divers objets complètement, partiellement enfouis ou non, parmi lesquels des mines sous-marines.

Le chapitre 2 se focalise sur les propriétés statistiques des images sonar et présente un panorama, non exhaustif des différents modèles utilisés pour les images sonar, considérées dans leur globalité. Cette partie ouvre la voie à la détermination de paramètres qui permettent de séparer les objets du fond bruité.

Ceci débute au chapitre 3 dans lequel sont mises en évidence les propriétés, aux ordres 1 (moyenne) et 2 (écart-type) des images au niveau local. Ces considérations nous permettent ensuite de développer un algorithme de segmentation utilisant une représentation moyenne / écart-type des données. Un critère d'entropie nous sert à automatiser ce processus en fixant un seuil "idéal" séparant les échos du fond marin. Le chapitre 4 présente un élargissement de ces moyens de détection aux statistiques d'ordres supérieurs. Les propriétés statistiques des images sonar à ces ordres et les grandeurs associées (skewness et kurtosis) nous fournissent alors un moyen supplémentaire de détection.

Le chapitre 5 propose une architecture de fusion tenant compte des particularités des paramètres (relation de proportionnalité entre la moyenne et l'écart-type entre autres). Ceci aboutit à une segmentation de l'image grâce à un processus très maniable et évolutif,

basé sur la théorie de l'évidence. Un commencement de validation d'objets est présenté à la fin du chapitre.



# Chapitre 1

## Détection en acoustique sous-marine

Apparue au XIX<sup>e</sup> siècle, et développée au début du XX<sup>e</sup> siècle, l'acoustique sous-marine a connu de nombreux progrès surtout après la Seconde Guerre Mondiale. Elle participe alors à de nombreuses applications civiles et militaire, notamment dans la chasse aux mines sous-marines qui font de nombreux dégâts y compris longtemps après un conflit.

Pour ce faire, de nombreux systèmes ont été développés, de plus en plus performants, avec, entre autres, des appareils permettant d'imager les fonds marins. En parallèle, de nombreuses méthodes de correction et de traitement des images ainsi obtenues ont été proposées, ainsi que pour la détection et la classification des objets présents sur celles-ci.

Ce mémoire propose alors de nouvelles méthodes de détection de ces objets à partir de leurs échos, et notamment ceux qui sont enfouis et présentent alors un très faible rapport signal à bruit. Ces méthodes sont testées et évaluées par la suite sur des données réelles issues d'un Sonar à Antenne Synthétique (SAS).

---

## Sommaire

---

<b>1.1</b>	<b>Introduction</b>	<b>11</b>
<b>1.2</b>	<b>L'acoustique sous-marine : histoire et applications</b>	<b>11</b>
1.2.1	Histoire de l'acoustique sous-marine	11
1.2.2	Principales applications civiles et militaires	12
1.2.2.1	Applications civiles	12
1.2.2.2	Applications militaires	13
1.2.3	Application à la chasse aux mines sous-marines	14
1.2.3.1	Les mines sous-marines	15
1.2.3.2	Le déminage	15
<b>1.3</b>	<b>Imagerie sonar et détection sous-marine</b>	<b>17</b>
1.3.1	Les systèmes acoustiques imageurs	17
1.3.2	Traitement des images sonar	18
1.3.2.1	Qualité des images sonar	19
1.3.2.2	Traitements usuels	20
1.3.2.3	Traitements avancés	21
1.3.3	Détection d'objets	22
1.3.3.1	Détection et classification sur ombres	22
1.3.3.2	Détection sur échos	25
<b>1.4</b>	<b>Problème posé</b>	<b>26</b>
1.4.1	Données traitées	26
1.4.1.1	Le sonar à antenne synthétique (SAS)	26
1.4.1.2	Description des données utilisées	28
1.4.2	Méthodes de détection proposées	30

---

## 1.1 Introduction

Dans ce chapitre, sont présentées quelques généralités sur la détection en acoustique sous-marine.

Ainsi, après un bref historique de l'acoustique sous-marine et une présentation des principales applications de celle-ci, nous décrivons les principaux systèmes permettant d'imager les fonds marins. Les principales méthodes de traitement de ces images et de détection sont également présentées. Enfin, nous décrivons différentes images issues de données Sonar à Antenne Synthétique (SAS) qui serviront d'exemples pour tester les méthodes proposées dans la suite de ce mémoire.

## 1.2 L'acoustique sous-marine : histoire et applications

### 1.2.1 Histoire de l'acoustique sous-marine

L'intérêt de l'utilisation des ondes acoustiques en milieu marin a été découvert au cours du XIX<sup>e</sup> siècle [Oll95]. Mais, mises à part quelques expériences d'écho-sondage, les problèmes techniques liés à l'émission et à la réception de ces ondes ont longtemps laissé le domaine de l'acoustique sous-marine à l'état d'idée. A la fin du siècle, l'acoustique sous-marine a commencé à se développer, suivant l'essor du téléphone, dans le domaine de la communication sous-marine. Au début du XX<sup>e</sup> siècle, bien avant que le radar ait apparu, le sonar (SOund Navigation And Ranging) était utilisé, couplé à des signaux radio et à la célèbre corne de brume, pour la signalisation des obstacles en mer.

C'est avec la Première Guerre mondiale que naquirent les premières applications militaires des ondes acoustiques, dans la lutte anti-sous-marine, développées grâce à l'utilisation de la piézoélectricité découverte trente cinq ans plus tôt. Apparurent alors les premiers sonars passifs, puis actifs, destinés à la localisation de cibles grâce aux échos réfléchis. Les années 1920 virent se développer les applications bathymétriques du sonar qui bénéficia en outre des débuts de l'électronique et de l'industrie naissante de la radio. Des sondeurs commencèrent alors à être utilisés pour la détection de bancs de poissons et se généralisèrent dans la navigation (détection d'obstacles). Mais c'est seulement la Seconde Guerre mondiale qui permit à l'acoustique sous-marine de prendre son essor, son utilisation étant déterminante dans les batailles opposant les navires alliés aux sous-marins allemands. Les fondements des connaissances actuelles en sonar datent de cette époque.

Après la fin des hostilités en 1945, la "Guerre Froide" et la course à l'armement entre les deux blocs ont permis à l'acoustique sous-marine de faire des progrès décisifs, autant à l'Ouest qu'en Union Soviétique. Ce progrès s'est surtout réalisé en ce qui concerne la portée des sonars passifs pour le contrôle de vastes zones maritimes, rendu nécessaire avec l'apparition des sous-marins nucléaires dans les années 1950. L'introduction des méthodes de traitement numérique du signal à la fin des années 1960, en parallèle avec l'évolution des performances des calculateurs, permit au sonar d'atteindre un degré de sophistication qui n'a eu d'égal que celle de la discrétion acoustique des sous-marins.

En parallèle apparurent les premières techniques d'imagerie utilisant les signaux rétro-diffusés d'un sonar latéral. L'évolution technologique des transducteurs et l'utilisation de vecteurs stabilisés et tractés permirent d'améliorer sensiblement la qualité des images qui, au début, étaient pauvres en résolution et fortement bruitées (bruits excessifs générés par le navire porteur et instabilité de celui-ci). L'apparition de sondeurs multifaisceaux dans les années 1970 donna un nouvel élan à cette application qui permit alors une cartographie acoustique des fonds marins de grande qualité débouchant sur de nombreuses applications (recherche pétrolière, hydrologie, climatologie et, plus récemment, protection de l'environnement).

## 1.2.2 Principales applications civiles et militaires

### 1.2.2.1 Applications civiles

L'acoustique sous-marine civile est un secteur relativement modeste, mais très varié et en pleine expansion, les secteurs actuellement porteurs étant l'ingénierie offshore, la pêche industrielle et les grands programmes scientifiques d'étude et de surveillance de l'environnement. Les principales catégories d'applications sont les suivantes [Lur02] (figure 1.1) :

- **La navigation** : les sondeurs bathymétriques associés à cette application permettent de mesurer la hauteur d'eau en émettant un signal vertical vers le bas en un faisceau étroit et en évaluant le retard de l'écho renvoyé par le fond. Ce type de système est présent dans la plupart des navires et certains bateaux de plaisance. Dans le même domaine, des systèmes de positionnement sont également utilisés, mesurant des temps de trajets d'ondes émises par des émetteurs fixes installés sur le fond, ceci en utilisant toute une batterie de techniques : base longue, courte, ultra-courte, base longue inversée, . . . Le positionnement peut être utilisé pour la trajectographie ou le recalage de mobiles sous-marins.
- **L'industrie de la pêche** : les sonars sont alors sensiblement les mêmes que les précédents et sont destinés à la détection et la localisation des bancs de poissons.
- **La cartographie marine** : les sonars utilisés sont alors de différents ordres selon la précision recherchée. Le plus simple, et le plus ancien, est le sonar latéral émettant des ondes très rasantes permettant de reproduire les irrégularités du fond marin sur une image acoustique. Les sondeurs multifaisceaux, un peu plus complexes, balayent eux une large bande de terrain sur le fond et en mesurent le relief. Ils permettent alors un relevé précis de la topographie des fonds marins.
- **La géologie et la recherche pétrolière** utilisent des sondeurs profileurs de sédiment, monofaisceau, mais de fréquence très basse permettant de pénétrer sur des profondeurs de plusieurs dizaines de mètres. Dans le même domaine sont utilisés des systèmes de sismique avec des sources explosives ou percussives et de grandes antennes de réception afin d'explorer le sous-sol sur plusieurs kilomètres de profondeur.
- **L'hydrologie** : les sonars utilisés sont alors soit des systèmes à effet Doppler permettant d'évaluer la vitesse de l'eau par rapport à un repère fixe (courantométrie Doppler), soit des réseaux de tomographie acoustique permettant de mesurer des

temps de trajets de l'onde acoustique (sur de grandes distances) ou des variations d'amplitude (sur de faibles distances). Ce dernier système permet d'étudier la structure de perturbations hydrologiques par la mesure de variations de célérité.

- **Les communications** : cette application est utilisée dans des domaines du type "téléphone sous-marin" ou pour la transmission de données numérisées. Mais les systèmes associés sont limités dans leurs performances par les faibles bandes passantes disponibles et les difficultés imposées par la propagation sous-marine.
- **Les recherches archéologiques**, bien qu'anecdotiques, mais assez populaires, utilisent des sonars latéraux, notamment pour la recherche d'épaves. De la même manière, l'acoustique sous-marine est utilisée pour la recherche d'objets (boîtes noires des avions,...) ou de victimes après une catastrophe en mer (exemple de la catastrophe aérienne de Charm-el-Cheikh du 3 janvier 2004).

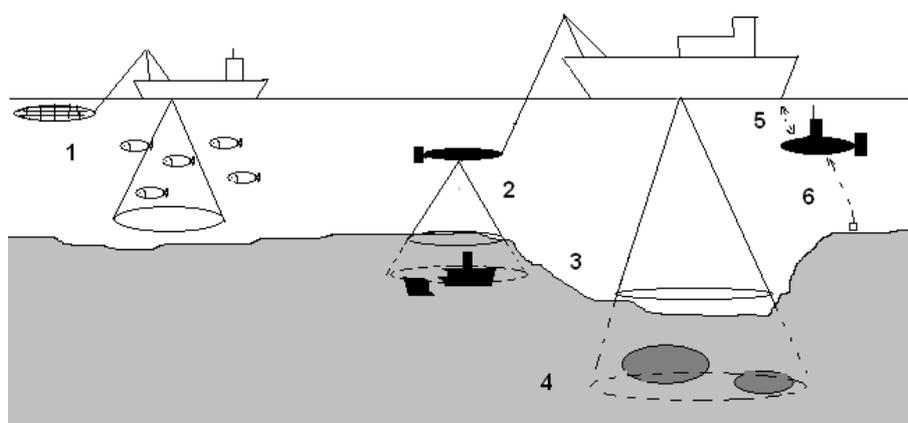


FIG. 1.1 – Quelques applications civiles de l'acoustique sous-marine.

- 1 : l'industrie de la pêche, 2 : les recherches d'épaves et les fouilles archéologiques,  
 3 : la cartographie marine, 4 : les études géologiques et la recherche pétrolière,  
 5 : les communications, 6 : la navigation (positionnement).

Cette énumération est loin d'être exhaustive, mais consigne les principales applications civiles de l'acoustique sous-marine.

### 1.2.2.2 Applications militaires

Les applications militaires concentrent l'essentiel des recherches et de l'industrie en acoustique sous-marine. Celles-ci consistent en la détection, la localisation et l'identification de deux types de cibles [Lur02] (figure 1.2) :

- **Les sous-marins** : les sonars utilisés pour cette application sont alors soit passifs, soit actifs. Les premiers, qui n'ont pas d'équivalent en applications civiles, sont destinés à intercepter des bruits émis par la cible. Leur intérêt est leur discrétion totale.

Outre la détection, ces sonars permettent la localisation de la cible par l'étude de la forme du champ acoustique reçu (dans le cas d'antennes de grande dimension), et l'identification à partir de la signature acoustique de la cible. Beaucoup moins discrets, les sonars actifs émettent un signal et recueillent les échos renvoyés par la cible. La mesure du retard permet alors de mesurer la distance entre le sonar et la cible, et la direction angulaire de la réception par un système approprié permet de donner des informations complémentaires sur la localisation. L'analyse de l'écho peut également donner des informations sur la nature et la vitesse de la cible (grâce à l'effet Doppler).

- **Les mines** : les sonars de chasse aux mines, actifs et de très haute performance en résolution, permettent de repérer et d'identifier des mines en zones littorales. Cette application sera développée dans le paragraphe suivant.

D'autres cibles peuvent également être détectées par ces moyens : les torpilles, les robots sous-marins,...

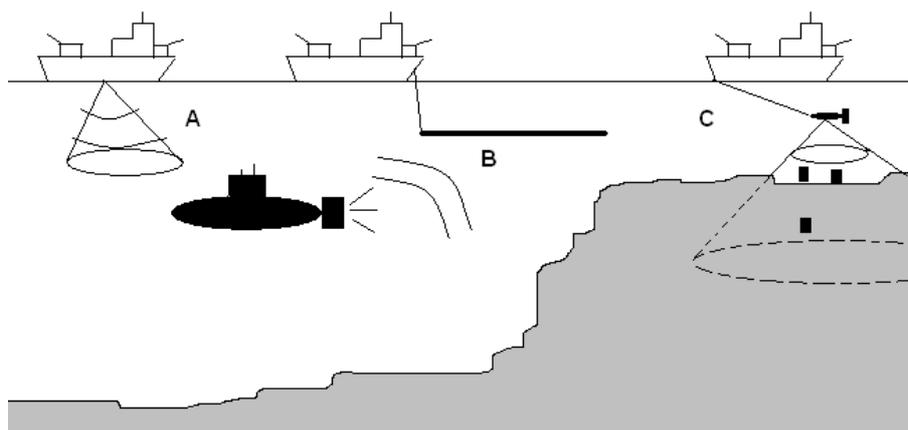


FIG. 1.2 – Quelques applications militaires de l'acoustique sous-marine.

A : la détection active de sous-marins, B : la détection passive de sous-marins,  
C : la détection de mines sous-marines.

Nous pouvons ainsi voir que l'acoustique sous-marine est présente dans un grand nombre d'applications civiles et militaires. Ces dernières, bien que moins variées et malgré le développement des applications civiles, concentrent encore toute l'attention des chercheurs et des industriels, notamment en ce qui concerne la chasse aux mines où les progrès dans les techniques de détection, de localisation et d'identification vont croissants.

### 1.2.3 Application à la chasse aux mines sous-marines

La chasse aux mines sous-marines est une application prépondérante de l'acoustique sous-marine [Hét03]. En effet, bien que mal connue, et beaucoup moins spectaculaire que

d'autres formes de guerres (aéronavales ou sous-marines), la guerre des mines est très ancienne et redoutable autant pour les navires militaires que pour les navires marchands et de plaisance, y compris longtemps après un conflit. C'est pourquoi cette activité intéresse au plus haut point les autorités nationales et internationales, autant pour protéger les capacités militaires de chaque pays, notamment la force de dissuasion française, que pour protéger la libre circulation des navires et la sécurité des ports à travers le monde.

### 1.2.3.1 Les mines sous-marines

Bien loin du feu grégeois (liquide incendiaire à base de naphte et de salpêtre), utilisé dès l'Antiquité pour attaquer les navires ennemis, les mines navales modernes restent de structures simples, peu coûteuses et d'utilisation aisée. Elles font ainsi figure, au même titre que leurs consœurs terrestres, d'"armes du pauvre". Ainsi, rien que durant le second conflit mondial, environ 700 000 mines sous-marines ont été mouillées, et pratiquement tous les conflits, et ce depuis la fin du XIX<sup>e</sup> siècle, ont fait l'objet de ce type d'activité militaire.

Les mines sous-marines peuvent être regroupées en cinq classes :

- **Les mines de fond** sont simplement posées sur le fond marin. Elle peuvent également être enfouies dans les sédiments sous diverses actions géodynamiques des fonds, ou "volontairement" par des systèmes complexes d'enfouissement,
- **Les mines à orins** sont reliées au fond par un filin d'acier,
- **Les mines dérivantes** sont des mines à orins dont le filin a été sectionné volontairement ou involontairement,
- **Les mines mobiles** se dirigent vers la cible, une fois celle-ci détectée,
- **Les mines contrôlées** répondent à l'action d'un opérateur humain.

Les mines modernes sont généralement de formes géométriques simples (sphériques, cylindriques à bouts droits ou hémisphériques, parallélépipédiques, figure 1.3). Nous trouvons parmi elles des coques métalliques et, plus récemment, non métalliques et de formes plus complexes afin de diminuer leur signature acoustique et rendre plus difficile leur détection. Les mises à feu de ces mines sont également variées : à contact pour les mines à orins et dérivantes, à influence magnétique, acoustique ou par dépression pour les mines à orins et de fond. Ces différents modes peuvent également être combinés.

### 1.2.3.2 Le déminage

Avant les années 1960, le déminage se faisait de manière aveugle par dragage ou contreminage. La chasse aux mines, par des méthodes non aveugles, est alors apparue et a pour but de repérer et de supprimer la mine. Les opérations de chasse aux mines peuvent alors être décomposées en quatre étapes importantes :

- **La détection** afin de recueillir les échos semblables à ceux que l'on recherche.
- **La classification** permet de trier ces informations afin de classer les objets détectés en mines ou non mine.

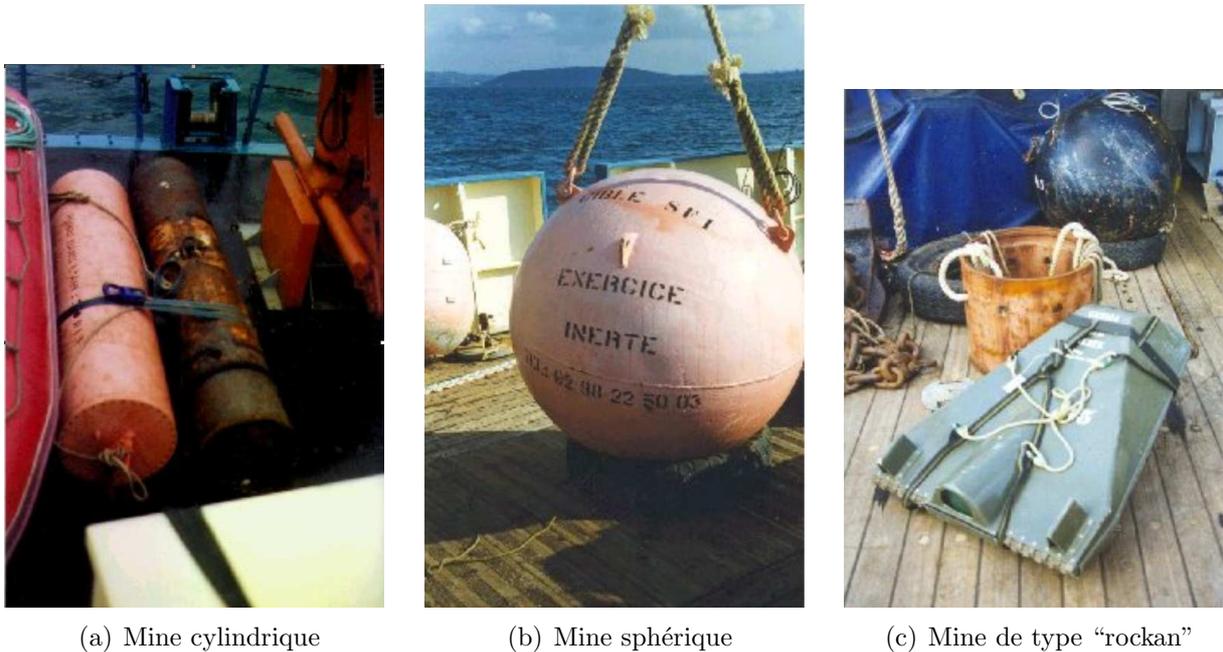


FIG. 1.3 – Exemples d’objets servant de modèles de mines sous-marines de fond.

- **L’identification** consiste à vérifier des contacts classifiés comme étant un objet mine.
- **La neutralisation** consiste en l’élimination, le désamorçage, l’enlèvement ou le balisage de la mine précédemment identifiée.

Le sonar prend alors toute sa place dans les deux premières étapes décrites ci-dessus. En effet, les autres systèmes de perception (vidéo, ondes électro-magnétiques, laser...) sont inadaptés au milieu marin, même s’ils peuvent être utilisés dans la phase d’identification à courte portée. Le sonar doit être capable de détecter et classifier de petits objets en formant des images haute résolution tout en maintenant la plate-forme de chasse aux mines à une distance de sécurité d’environ 200 m par rapport à la cible. Les hautes fréquences limitant la distance de propagation des ondes acoustiques, il est d’usage de différencier les fonctions “détecteur” et “classificateur” d’un sonar. Le sonar “détecteur” travaille ainsi avec des fréquences plus faibles, et donc avec une moins bonne résolution, mais opère plus loin de la menace potentielle que le sonar “classificateur” qui, en contre partie, fournit des signaux de meilleure résolution, en émettant des signaux de plus hautes fréquences. Afin de pouvoir positionner et reconnaître la forme des objets recherchés, il est souhaitable de pouvoir séparer les signaux en fonction de leurs directions d’arrivée et de former des images multidimensionnelles de l’environnement.

Ces sonars étaient au début fixés à la coque d’un navire chasseur de mines. Afin de rapprocher le sonar du fond de la mer, et donc l’éloigner du navire source de bruit, mais aussi pour augmenter la rasance pour une meilleure classification des objets, les premiers VDS (*Variable Depth Sonar*) apparurent dans les années 1960. Les sonars à visions latérales

montés sur des poissons (vecteur remorqué par un navire chasseur de mines) sont un exemple de VDS, avec une résolution élevée. Une plus grande autonomie de fonctionnement de ces véhicules de détection a alors été recherchée, à partir des années 1990, afin de protéger encore mieux les navires chasseurs de mine, en élevant la distance de sécurité. C'est ainsi que sont apparus des véhicules télé-opérés (ROV, *Remote Operated Vehicle*) porteurs d'un système sonar, des drones de surface (USV, *Unmanned Surface Vehicle*), et, plus récemment, les AUV (*Autonomous Underwater Vehicle*) qui possèdent une grande autonomie énergétique et décisionnelle.

## 1.3 Imagerie sonar et détection sous-marine

Dans cette partie, nous allons nous intéresser dans un premier temps aux différents systèmes utilisés pour la détection en acoustique sous-marine. Les systèmes imageurs sont prépondérants dans la détection, la localisation et la classification des mines sous-marines ou de tout autre objet. En effet, les sonars monofaisceaux, d'utilisation simple et de faible consommation, ne sont pas suffisants pour une bonne localisation et caractérisation des objets recherchés. Dans un second temps, nous allons faire un état des lieux sur les traitements et les méthodes appliquées sur les images produites par ces systèmes afin d'améliorer ou de permettre la détection, voire la classification des objets présents dans l'image.

### 1.3.1 Les systèmes acoustiques imageurs

Quatre approches principales sont utilisées pour former les images en acoustique sous-marine [LLFZ03] :

- **Les réseaux d'échosondeurs** sont constitués de séries d'échosondeurs simples, disposés dans des directions différentes. Ces échosondeurs doivent être suffisamment directifs afin que les informations apportées par chacun soient complémentaires. Cette technique est très compétitive tant que le nombre de directions reste faible. Mais, la gestion d'une série de sondeurs peut être difficile (synchronisation, couplages).
- **Les sonars à dépointage mécanique** sont constitués d'un sondeur monofaisceau monté sur une platine orientable. On utilise alors un seul capteur acoustique à ouverture étroite et les ondes sont émises régulièrement pendant que le capteur tourne sur lui-même. On obtient alors une image du fond tout autour du sonar.
- **Les sonars latéraux** sont composés de deux capteurs monofaisceaux fixés de part et d'autre du véhicule, avec une ouverture étroite dans le sens horizontal (azimut), et une ouverture large dans le sens vertical (site). L'ouverture en site, permet à chaque émission d'insonifier une grande largeur du fond. Les détails des échos sur cette bande sont alors résolus temporellement par les différences dans les dates d'arrivée. L'image du fond est alors formée par le mouvement du véhicule perpendiculaire à la direction pointée par le sonar.
- **Les sonars multifaisceaux** consistent en une antenne capteur formée de plusieurs hydrophones. Il est alors possible de calculer en parallèle plusieurs formations de voies

correspondant à des directions différentes. Si le nombre de voies est suffisamment important, on obtient une image complète de la zone correspondante du fond marin. Contrairement au réseau d'échosondeurs, chaque hydrophone contribue à toutes les voies et non à une seule direction. Ainsi, pour une même surface de capteurs, le système sera plus résolu et plus sensible (pour une antenne composée de  $N$  hydrophones, on obtient un gain de résolution d'un facteur  $N$  et de sensibilité d'un facteur  $10 \log_2 N$ ). Ce type de sonar peut être utilisé sur un sonar frontal : le système est alors orienté devant le véhicule légèrement vers le bas et on insonifie avec un faisceau large en site et large en azimut. A la réception, les voies sont formées en azimut et permettent d'avoir une image du fond.

Grâce aux progrès de l'électronique numérique, de nouveaux systèmes sonars apparaissent, dont certains ne sont aujourd'hui encore qu'au stade de prototype [LLFZ03].

- **La caméra acoustique**, dans le prolongement des sonars très simples donnant une information monodimensionnelle et des autres permettant de former des images bidimensionnelles, fournit des données tridimensionnelles. Pour cela, on utilise une antenne en T ou une antenne planaire.
- **Le sonar interférométrique** utilise au moins deux antennes latérales superposées et exploite le déphasage des signaux reçus sur les deux capteurs pour en déduire leur direction d'arrivée.
- **Le sonar à antenne synthétique (SAS)** : son principe consiste en l'intégration cohérente des signaux de voies d'une antenne réelle sur plusieurs récurrences successives, constituant l'antenne synthétique. Une présentation plus détaillée de ce système sera faite dans le paragraphe 1.4.1.
- **Le sonar à synthèse incohérente** : contrairement au sonar précédent, les signaux des antennes successives sont sommés en énergie et non en tenant compte de leur phase respective. Le gain en résolution est alors plus faible, mais le bruit est sensiblement diminué.
- **Le sonar paramétrique** permet de construire des images "haute résolution" dans le sédiment, ce qui paraît *a priori* contradictoire. Il utilise pour cela deux fréquences qui se combinent. Ce système fait encore l'objet d'études.

Nous pouvons ainsi voir que de nombreux systèmes d'imageries différents existent. Le choix de la technologie à utiliser pour une application donnée se fait alors en considérant plusieurs choses : les capacités en termes d'encombrement, de calcul et de coût dont on dispose, la nature et la position des objets que l'on recherche (volume, enfouissement, ...).

### 1.3.2 Traitement des images sonar

Une fois les images acquises au moyen d'un système acoustique imageur, celles-ci ne peuvent être interprétées directement à cause des imprécisions de la mesure et du bruit présent sur les images. Un certain nombre de traitements est alors indispensable, pour certains, ou seulement utiles pour d'autres selon l'utilisation que l'on fait des images. Ils s'avèrent nécessaires en particulier pour des applications de robotique sous-marine.

### 1.3.2.1 Qualité des images sonar

Malgré les nombreux progrès réalisés dans l'acoustique sous-marine depuis ses balbutiements (voir le paragraphe 1.2.1), et le professionnalisme des personnes effectuant les mesures, les images obtenues par un système acoustique sous-marin sont souvent très dégradées, surtout pour les systèmes basses fréquences.

Cette dégradation peut, tout d'abord, provenir du milieu de propagation des ondes acoustiques. En effet, même dans des conditions favorables (eaux calmes,...), les caractéristiques du milieu marin peuvent largement influencer les résultats des mesures et avoir des répercussions sur la performance d'un système acoustique. Celles-ci peuvent être de différents ordres [Lur02] :

- **L'atténuation** des signaux transmis, due en particulier à l'absorption des ondes sonores dans l'eau, mais aussi, et majoritairement, à la divergence géométrique (propagation sphérique des ondes), va limiter les portées possibles d'un système donné.
- **Les hétérogénéités** du milieu marin peuvent perturber la propagation des ondes à cause de variations de célérité dues à des variations de température et de pression (couches bathycélérimétriques) ou à la présence de particules en suspension. Ceci peut de plus provoquer l'apparition d'échos parasites et d'interférences à cause de la présence de trajets multiples de l'onde.
- **Les réflexions** sur la surface ou le fond de la mer peuvent également provoquer des déformations dans les signaux transmis.
- **Le bruit ambiant** dans le milieu marin, provoqué par l'agitation de surface, le trafic maritime, les organismes vivants (baleines, dauphins,...), la pluie,... tend à masquer le signal utile, surtout lorsqu'on travaille à basses fréquences (inférieures à une centaine de kilohertz).
- **Les obstacles parasites**, comme les bancs de poisson, peuvent créer des échos parasites sur les fonds marins.

De plus, ces caractéristiques sont fluctuantes à la fois dans l'espace et dans le temps. Ceci est dû aux variations géographiques et saisonnières de la température et de la salinité, du relief du fond, des courants et des tourbillons.

La lenteur de propagation des ondes sonores implique que les mouvements de plateforme pendant la construction de l'image influent sur le résultat obtenu. En effet, les mouvements de lacet et de tangage impliquent une déformation de l'image (répétition de faisceaux ou, au contraire, trous de couverture) et peuvent entraîner une atténuation de l'énergie reçue, l'antenne pouvant être dépointée entre l'émission et la réception. Le pilonnement du support du sonar entraîne une distorsion du profil du fond à la verticale du véhicule. Le bruit du navire chasseur de mines peut également masquer le signal utile.

Le sonar lui-même peut provoquer des dégradations du résultat, notamment par le bruit électrique généré par l'électronique de réception (surtout en hautes fréquences), voire par le bruit propre du système. Celui-ci dépend de la bande de fréquences de réception du sonar, de la température ambiante et du gain du préamplificateur [Bou92].

Enfin, une caractéristique propre aux ondes cohérentes, ce qui est le cas des ondes acoustiques (on retrouve cette propriété dans les images radar), et ne dépendant pas des

conditions de la mesure, perturbe l'image résultat et lui donne un aspect granulaire. En effet, chaque cellule de résolution correspond à la contribution constructive et destructive d'un ensemble de points brillants (microréfecteurs : sable, petits cailloux, . . .) [Goo76]. Sur chaque point de l'image, nous aurons alors non pas directement la valeur de l'index, mais une valeur aléatoire de variance fonction de cet index. Le chatolement qui en résulte est appelé speckle et est considéré, selon cette dernière propriété, comme un bruit multiplicatif. La réverbération associée dépend de plusieurs facteurs [Bou92] : la durée des impulsions, la directivité des antennes d'émission et de réception, le niveau du signal émis, la texture du fond et l'angle d'incidence des rayons sonores. Par contre, elle dépend très peu de la fréquence d'émission du système. La modélisation statistique du bruit de speckle fera l'objet d'un chapitre détaillé dans cette thèse (chapitre 2).

### 1.3.2.2 Traitements usuels

Nous avons vu dans le paragraphe précédent que de nombreux facteurs dégradent sensiblement les images obtenues à partir d'un système sonar et peuvent nuire à leur interprétation. Certains traitements usuels sont alors proposés afin de réduire au maximum cette dégradation. Ces traitements ont pour buts principaux la correction et le conditionnement des données [LLFZ03]. Les principales étapes sont :

- **La correction de gain** permet de compenser des variations de luminance en fonction de la portée de l'émetteur (conséquence de l'atténuation de l'onde dans l'eau). Cette correction se fait généralement par une normalisation afin d'obtenir une moyenne et une variance indépendante de la portée. Cette méthode a pour inconvénient de fortement dégrader l'image surtout si on l'utilise afin de discriminer différents types de fond, mais elle peut s'avérer suffisante pour la détection d'objets.
- **La détection de la colonne d'eau** consiste en l'évaluation de la distance du fond. Ceci permet alors de connaître la géométrie de l'image. Cette mesure se fait en général par un filtre détecteur de bord sur la partie temporelle du signal. Il peut alors s'avérer difficile de séparer le fond réel de tout autre signal émergeant dans la colonne d'eau (bancs de poissons, bruit en surface, parasites divers, . . .). Il est alors possible d'utiliser des filtres morphologiques pour détruire les fausses alarmes ou de rechercher des connexités entre les zones de fonds détectées et les zones d'ombre si celles-ci sont présentes. Une autre solution est l'utilisation d'un simple filtre passe-bas sur les hauteurs détectées.
- **La correction géométrique** permet de représenter les résultats dans un espace où le signal est approximativement une projection conforme. Cette correction permet de corriger les mouvements de la plate-forme support du sonar, mais également les variations de résolution, notamment pour les sonars frontaux dont les voies sont souvent associées à une direction angulaire. Pour le premier point, l'utilisation d'une mosaïque d'images est fréquente et les paramètres de navigation enregistrés lors de la campagne de sondage sont très souvent utilisés.
- **Le sous-échantillonnage des données** est souvent appliqué dans le cadre d'un traitement automatique ou d'une visualisation des images sonar, ceci afin de réduire

le nombre de données généralement nombreuses. On profite généralement de cette étape pour réduire l'effet du speckle, en moyennant les points voisins par exemple.

### 1.3.2.3 Traitements avancés

Les traitements, relativement simples, présentés ci-dessus s'avèrent généralement très utiles pour une bonne visualisation, et ensuite une bonne interprétation, des images sonar. Mais ils peuvent être insuffisants pour certaines applications et certaines méthodes de détection complexes.

Après les traitements classiques, il peut alors être nécessaire d'appliquer sur l'image résultante des outils avancés de traitement d'images. Parmi ceux-ci, les plus courants sont les filtres.

Une première catégorie de filtres comprend les **filtres scalaires**. Ceux-ci sont appliqués directement sur l'image, pouvant avoir subi préalablement un des traitements simples présentés ci-dessus. Parmi ces filtres, on trouve les filtres moyennants simples évaluant les moyennes sur des fenêtres glissantes, ce qui permet de lisser le bruit, mais détériore également les éléments servant à l'interprétation de l'image et la détection des objets (relief du fond, échos, ombres, ...). Une amélioration de ce filtre est apportée par le filtre moyennant adaptatif qui ne prend pas en compte dans le calcul des moyennes les pixels de valeurs "aberrantes", ce qui permet de préserver les échos tout en lissant le fond bruité. Des filtres plus complexes existent comme le filtre à diffusion anisotrope, le filtre médian ou le filtre  $\alpha$  pondéré [CI8].

Certains de ces filtres scalaires peuvent être spécialement adaptés aux propriétés du speckle, dont on veut limiter l'effet, et en particulier à sa nature multiplicative. La plupart de ces filtres sont issus de l'imagerie radar [BCIL99], comme les filtres homomorphiques [CR02] qui transforment le bruit multiplicatif en bruit additif en prenant le logarithme des valeurs de l'image et filtre le résultat par un filtre simple (moyennant par exemple). Un autre exemple est le filtre de Lee [Lee81] qui utilise la variance et la moyenne du bruit. Une fois ces grandeurs évaluées, elles sont combinées afin de réduire l'effet du speckle en utilisant sa propriété multiplicative.

Une autre catégorie de filtres, les **filtres vectoriels**, travaille sur l'image après une décomposition de celle-ci en plusieurs images correspondant à différentes sous-bandes de fréquences [CHMT02]. Ces sous-bandes peuvent alors être filtrées séparément ou de façon combinée. Une sommation incohérente ou cohérente [CHMT02] des sous-bandes résultantes peut alors suivre.

Ces différents outils avancés de traitement d'images ont pour but de lisser au maximum les dégradations des images sonar, et notamment de limiter l'effet du speckle, tout en essayant de préserver les éléments pouvant servir à la détection, la localisation et la classification des objets recherchés. Une description plus détaillée de certains de ces filtres est présentée dans l'annexe A).

### 1.3.3 Détection d'objets

Les images sonar ont souvent pour utilisation la détection, puis la classification d'objets posés sur le fond marin ou enfouis dans le sédiment, et principalement, les mines sous-marines. C'est cette application qui nous intéresse dans ce mémoire. Pour cela nous utilisons les caractéristiques des images sonar et notamment celles qui apparaissent lors de la présence d'un objet dans le champ balayé par le sonar. La plupart des méthodes de détection et de classification à partir d'images sonar cherchent alors à isoler et à caractériser trois régions différentes sur les images (figure 1.4) :

- **Les ombres** qui, si elles sont présentes, sont composées de pixels d'intensité plus faible que le voisinage. Elles apparaissent le plus souvent à l'arrière (par rapport à l'émission) d'un objet posé sur le fond ou d'une rupture marquée dans le relief du fond.
- **La réverbération**, pixels de valeurs moyennes, correspondant au fond bruité.
- **Les échos** correspondant à des pixels généralement d'intensité plus élevée associés à la présence d'un fort réflecteur. Il peut alors s'agir d'un objet ou d'une rupture brutale de pente dans le fond.

La présence de ces éléments et leurs caractéristiques permettra de détecter, de localiser et, éventuellement, de classifier les objets présents dans l'image. Ces régions peuvent être plus ou moins bien séparées à l'"œil nu" selon les conditions de la mesure, les fréquences d'émission et la position des objets (enfouissement, éparpillement, nature du terrain, ...). La détection et la classification privilégieront alors, selon l'application, la recherche et la caractérisation des ombres ou des échos.

#### 1.3.3.1 Détection et classification sur ombres

Pour les objets posés sur le fond, l'image sonar obtenue est facilement interprétable. En effet, une ombre acoustique est projetée par l'objet insonifié sous une certaine rance et occulte totalement plusieurs voies de réception (figure 1.5). Lorsque le nombre de voies acoustiques formées en réception est suffisamment important, l'analyse de la forme de l'ombre permet de retrouver celle de l'objet. En effet, une ombre ellipsoïdale est caractéristique d'un objet sphérique, une ombre en forme de parallélépipède rectangle, d'un objet cylindrique, etc. La qualité de l'ombre acoustique s'évalue par le contraste entre le signal de réverbération de fond et l'absence de signal masqué par l'objet : c'est le contraste réverbération / ombre (le bruit présent sur les capteurs en présence d'une ombre proviennent non seulement du bruit électrique décrit ci-dessous, mais aussi du signal contenu dans les lobes secondaires, les signaux parasites issus de réflexions liées aux multi-trajets, du bruit ambiant, voire d'un phénomène d'ombre différentielle en sonar à antenne synthétique). L'ombre peut être mise en évidence en appliquant les filtres décrits dans le paragraphe précédent.

Une première étape consiste alors à isoler ces ombres par rapport au reste de l'image. Ceci peut s'effectuer par simple seuillage à partir d'un histogramme de l'image, en sélectionnant les pixels de faibles valeurs par rapport aux autres. Un algorithme des K-moyennes

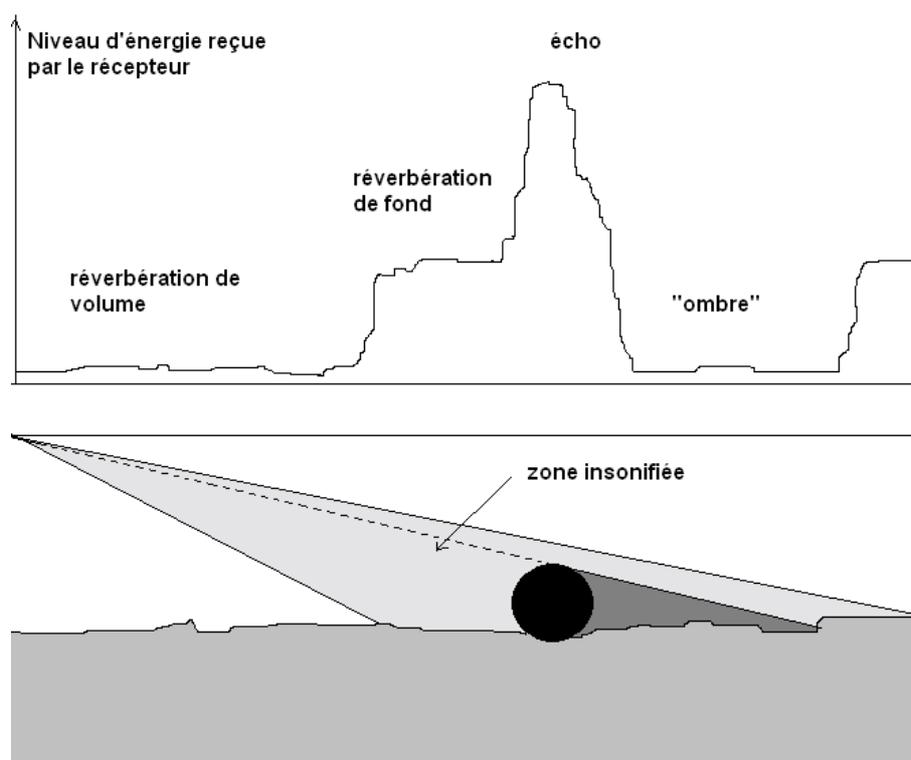


FIG. 1.4 – Principe de la détection d’objets sur les images sonar.

peut également être utilisé [MCPB97]. Pour ce faire, un certain nombre de paramètres est évalué sur une fenêtre glissant sur toute l’image (moyenne, variance, niveau de gris minimum par exemple) et les pixels sont alors regroupés, selon leurs proximités mutuelles dans le repère formé par les paramètres, en deux groupes correspondant à une région “ombre” et une région “réverbération”. Les résultats obtenus sont généralement satisfaisants, mais nécessitent le plus souvent un filtrage morphologique ou de type médian pour réduire le bruit [LLFZ03].

Des méthodes de segmentation plus complexes ont été proposées utilisant des champs de Markov et des modèles statistiques du bruit [MCPB97, Mig98, CTM<sup>+</sup>98]. Le résultat obtenu à partir des K-moyennes sert alors d’initialisation à un algorithme cherchant à regrouper les pixels des régions correspondant aux ombres selon leur position par rapport à d’autres pixels associés aux ombres (en utilisant des connaissances *a priori*) et les modèles statistiques estimés sur toute l’image pour la réverbération et les ombres. Une autre méthode utilise pour cette segmentation une “carte auto-organisatrice” (SOM, *self-organizing map*) incluant une étape d’apprentissage avant la segmentation markovienne [YMC<sup>+</sup>00]. D’autres approches ont été proposées afin d’améliorer les performances et les potentialités de la segmentation markovienne [Mig98, CTM<sup>+</sup>98] : une approche multi-résolution effectuant une discrétisation spatiale des observations à différents niveaux de résolution aboutissant à une représentation pyramidale des données, une approche marko-

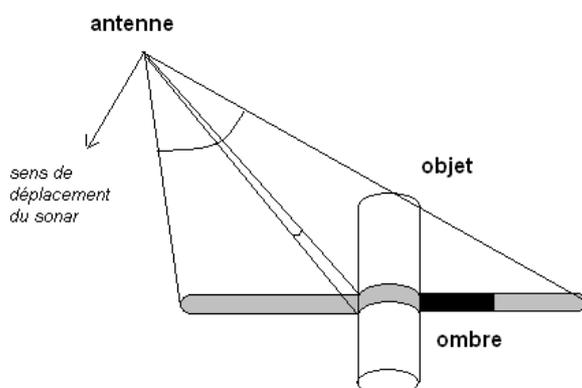


FIG. 1.5 – Principe de la classification sur ombre.

vienne hiérarchique multimodèle avec un modèle markovien différencié selon l'échelle de représentation des données.

Une deuxième étape du processus de détection consiste alors à caractériser les ombres segmentées. Pour cela plusieurs approches plus ou moins simples et plus ou moins performantes existent [Mig98]. Tout d'abord, on se munit d'une bibliothèque de formes prototypes, géométriquement simples, que l'on pourra déformer (rotation, élongation, biais, . . .) afin de les faire correspondre le plus possible aux ombres segmentées sur l'image. Pour effectuer ces déformations et les transposer sur l'image, on utilise des algorithmes évaluant un terme d'énergie que l'on essaiera de minimiser par des techniques d'optimisation (descente de gradient, recuit simulé) [MCPB00] ou un algorithme génétique [MCPB98, MCPB00, QMB03]. Une autre solution est l'utilisation d'un algorithme de *snake*, utilisant des connaissances *a priori* sur les relations spatiales entre les ombres et les échos, afin de caractériser au mieux les ombres en leur transposant des formes complexes [RPB03].

Afin d'améliorer la détection, l'association entre une ombre et un écho peut être recherchée. Ceci peut se faire en ajoutant une région "écho" à la segmentation [JD94]. Ainsi, tout en gardant une approche markovienne, on décompose la région de l'image non associée à une ombre en deux régions "écho" et "réverbération". On utilise alors l'*a priori* selon lequel un écho est forcément proche d'une ombre d'une taille raisonnable, pour pouvoir les segmenter correctement [Mig98, MCPB99]. Tout comme pour les ombres, ces échos segmentés peuvent être caractérisés en estimant leurs contours [RPB03]. Une autre approche consiste à se donner des modèles d'associations ombre-écho, que l'on peut déformer, pour les transposer sur l'image sonar segmentée pour réaliser une caractérisation des objets présents [Faw03] par corrélation [HD95] ou morphologie mathématique [BG01].

### 1.3.3.2 Détection sur échos

Les petits objets, comme les mines sous-marines, sont plus facilement détectés par la forme de leur ombre que par l'écho. Il y a essentiellement trois raisons à cela :

- le speckle entraîne une fluctuation forte de l'intensité des échos,
- la réflexion se fait principalement sous la forme d'un très faible nombre de points brillants,
- les ombres sont généralement très étendues (fonction de la rasant) et composées d'un très grand nombre de pixels permettant une meilleure interprétation de l'image.

Pour ces raisons, les ombres sont privilégiées pour la détection et la classification des objets et la plupart des études faites sur la détection d'objets en acoustique sous-marine a été faite en utilisant les ombres, les échos servant le plus souvent d'éléments de "confirmation".

Mais, dans certains cas, ces ombres sont peu visibles, voire totalement absentes des images sonar malgré la présence d'un objet. C'est notamment le cas lorsque les objets sont enfouis dans le sédiment marin.

Quand on parle de l'enfouissement des objets, nous considérons seulement celui dans la première strate du sédiment. Afin de détecter ces objets, les ondes acoustiques doivent passer l'interface et se propager dans le volume. Les propriétés de cette propagation (atténuation, réverbération), bien entendu liées à celles du milieu, influent directement sur l'image obtenue. La forte atténuation provoquée par le sédiment oblige alors à utiliser des basses fréquences pour l'émission (entre 2 et 30 kHz), ce qui fait perdre en résolution sur l'image sonar, et donc en détection.

Les ombres étant absentes dans ce cas, à cause de la réflexion par le fond marin au dessus de l'objet et de la faiblesse de la résolution, la détection de ce type d'objet oblige à utiliser les échos comme éléments principaux. Ces éléments étant généralement de très petite taille et peu visibles (surtout dans le cas d'objets enfouis et d'objets de faible réflectivité), les méthodes de détection, et surtout de classification, sont assez délicates à mettre en oeuvre, un simple seuillage étant la plupart du temps insuffisant pour distinguer les échos du reste de l'image bruité par du speckle.

L'approche la plus fréquemment utilisée peut se décomposer en deux étapes. La première est de sélectionner des régions d'intérêt, plus ou moins grandes, contenant les échos. Pour ce faire, plusieurs techniques peuvent être utilisées : en utilisant des filtres tels que présentés dans le paragraphe précédent permettant de rehausser les échos et en sélectionnant les régions ayant une valeur plus élevée que la moyenne [AFD97], en utilisant plusieurs paramètres (moyenne, variance, lacunarité, ...) évalués localement sur l'image (sur une fenêtre glissante) [Kes02, PG04] ou en cherchant un contour englobant un ou plusieurs échos [FMRT97].

Une fois les régions d'intérêts localisées, plusieurs paramètres statistiques (moyenne, variance, ...), morphologiques (taille, périmètre, forme, ...) ou autres (contraste, entropie, ...) peuvent être extraits de ces régions et fusionnés. Le processus de fusion, basé sur la vraisemblance, éventuellement après orthogonalisation [AFD97, AFD01, AFD03a, AFD03b], par analyse en composantes principales [LS94], ou par réseau de neurones [PG04] permet alors une identification des échos comme appartenant à un objet recherché ou non, après

une réduction des fausses alarmes.

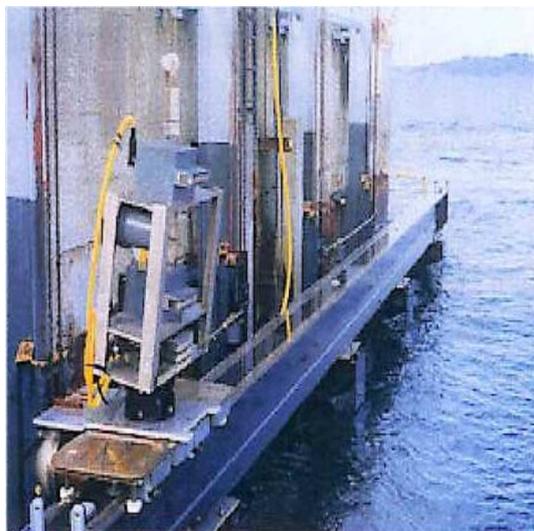
## 1.4 Problème posé

Comme présenté dans l'introduction de ce mémoire, le problème étudié ici est celui de la détection d'objets sur échos en utilisant des outils d'acoustique sous-marine. On s'intéressera plus particulièrement au cas des objets enfouis dans les premières couches du sédiment marin.

### 1.4.1 Données traitées

#### 1.4.1.1 Le sonar à antenne synthétique (SAS)

Les données sur lesquelles les résultats seront présentés dans ce mémoire sont toutes issues d'un sonar à antenne synthétique (SAS) (figure 1.6). Issues du radar à ouverture synthétique (ROS, en anglais *SAR*, *synthetic aperture radar*) apparu dans les années 1950 pour former des images haute résolution à partir de radars aéroportés, puis spatiaux, les premières études sur le SAS ont été effectuées dans les années 1970 [Haw96, Hét03, HG04]. Le principe du sonar à antenne synthétique est illustré sur la figure 1.7.



(a) Transducteur sur son rail



(b) Transducteur immergé

FIG. 1.6 – Images d'un sonar utilisé comme SAS.

En effet, dans le cas général des sonars, une large bande de fréquences  $B$  utilisée pour l'émission des ondes acoustiques permet d'avoir une excellente résolution en site, après filtrage adapté. La résolution en site est alors donnée par la formule :

$$\delta_r \approx \frac{c}{2B} \quad (1.1)$$

$c$  étant la vitesse de propagation de l'onde sonore dans le milieu marin. Pour un site  $x$  donné, la résolution en azimuth est alors donnée par :

$$\delta_{\text{az}} \approx \frac{x\lambda}{d} \quad (1.2)$$

avec  $d$  la dimension latérale du sonar et  $\lambda$  la longueur d'onde de l'onde acoustique. Afin d'accroître la valeur du facteur  $d$ , et donc d'améliorer la résolution, il est possible d'utiliser une antenne de grande dimension composée de plusieurs capteurs et d'utiliser une formation d'antenne. La résolution précédente devient alors :

$$\delta_{\text{az}} \approx \frac{x\lambda}{2L_a} \quad (1.3)$$

avec  $L_a$  la longueur de l'antenne ainsi formée.

Le sonar à antenne synthétique propose alors, au lieu d'utiliser une longue antenne qu'il peut s'avérer impossible de réaliser pour des raisons techniques ou de coût, d'utiliser un seul capteur en mouvement, ayant de préférence un déplacement rectiligne [CBZ92]. Ce mouvement peut être celui du navire ou du véhicule porteur ou un rail rectiligne sur lequel est fixé le sonar. Ceci permet alors de simuler une antenne de grande dimension (figure 1.8). Nous obtenons alors une image sonar comme celle présentée sur la figure 1.9(a) où nous pouvons remarquer un certain nombre de structures brillantes en forme d'hyperboles correspondant aux échos. Ces structures s'expliquent par le principe même du SAS (figure 1.8). Après focalisation (par compensation des retards) et compensation des mouvements du porteur du sonar, nous obtenons une image telle que celle de la figure 1.9(b).

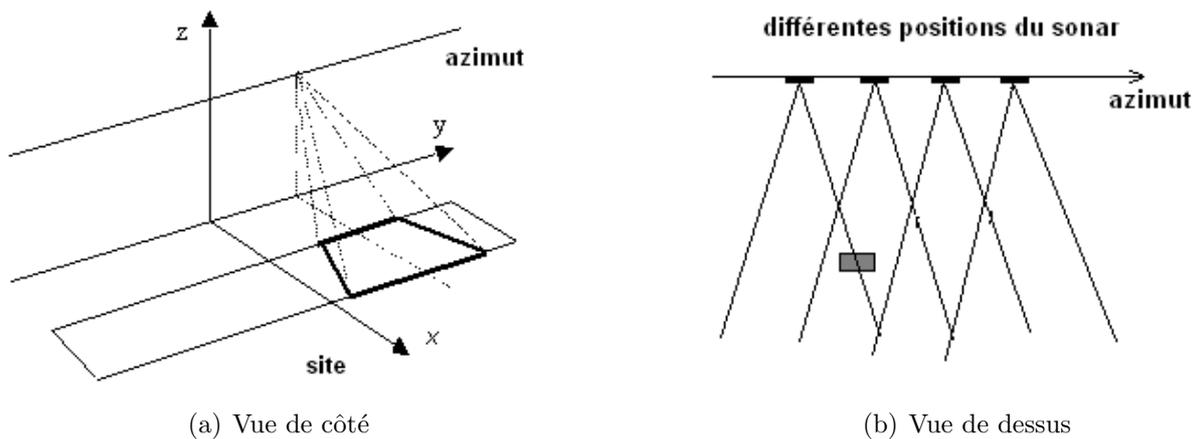


FIG. 1.7 – Principe du sonar à antenne synthétique.

Le sonar à antenne synthétique trouve tout son intérêt dans la détection d'objets enfouis. En effet, il permet d'améliorer sensiblement la résolution (en augmentant le terme  $L_a$  de l'équation 1.3) tout en conservant une fréquence d'émission faible (inverse du terme

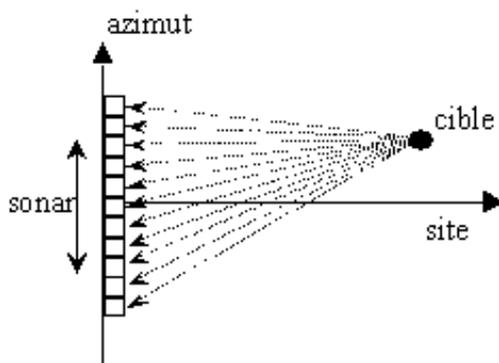


FIG. 1.8 – Principe de la synthèse d’ouverture.

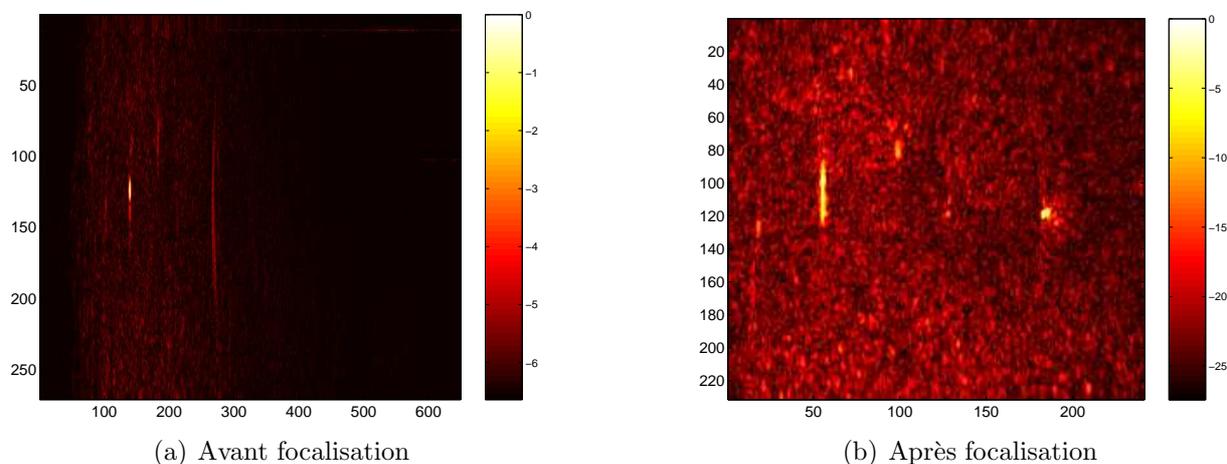


FIG. 1.9 – Exemple de formation d’une image SAS (échelle en dB, coordonnées en pixels).

$\lambda$ ) permettant à l’onde acoustique de pénétrer profondément dans le sédiment marin. C’est pour cela que le sonar à antenne synthétique a toute sa place dans la détection d’objets enfouis, notamment les mines sous-marines, et fait encore l’objet de recherches actives [LLFZ03, HG04].

#### 1.4.1.2 Description des données utilisées

Dans ce mémoire, tous les résultats seront présentés sur un certain nombre de jeux de données ayant des propriétés différentes et contenant des objets de natures et de positions tout aussi différentes. Pour une meilleure visualisation, toutes les images sont représentées en utilisant une échelle en décibels (dB). 0 dB correspond alors à l’amplitude maximale des pixels de l’image. Les traitements proposés sont eux, bien entendu, appliqués à l’image normale. Notons que dans la description de ces images qui suit, le terme “mine” fait référence, en fait, à un objet simulant une mine sous-marine (exemples de tels objets sur la figure 1.3).

Un premier jeu de données (figure 1.10(a), image A), issu de la campagne IFSAS'99 (*InterFerometric Synthetic Aperture Sonar*) réalisée par le GESMA (Groupe d'Etudes Sous-Marines de l'Atlantique, DGA/DCE/GESMA, Brest) et la DERA (*Defense Evaluation and Research Agency*, Royaume-Uni) [Hét00] a été obtenu avec un sonar d'une bande d'environ 60 kHz (à 3dB), et de fréquence centrale 150 kHz, se déplaçant le long d'un rail rectiligne. L'antenne est composée de 64 éléments distribués régulièrement, à une distance  $\lambda/2$ , répartis en quatre modules différents. L'image représente une région d'environ 20 m sur 10 m du fond marin avec une définition (taille d'un pixel) d'environ 1 cm dans les deux dimensions. La résolution attendue, en tant que distance minimale entre deux objets que l'on peut séparer visuellement, est elle d'environ 5 cm. L'amplitude maximale des pixels est approximativement de  $1,8 \cdot 10^5$ . Sur cette image, deux mines sous-marines sont présentes :

- Au bas de l'image, une mine sphérique est posée sur le fond. On peut la reconnaître par l'ombre elliptique très visible, projetée à l'arrière,
- En haut, une mine de type "rockan" que l'on reconnaît grâce à l'ombre triangulaire et les échos présents au devant de cette ombre.

Une autre image, de résolution équivalente (figure 1.10(b), image B) et obtenue lors de la même campagne d'expérimentations, représente une région de taille à peu près équivalente également. L'amplitude maximale est d'environ  $3,6 \cdot 10^4$ . Ici sont présentes également deux mines sous-marines posées sur le fond marin : une mine sphérique en haut et une mine cylindrique en bas (voir l'ombre rectangulaire projetée).

Il est évident que pour les deux images décrites ci-dessus la détection des mines ne pose pas problème, les objets étant reconnaissables à l'oeil nu (rapport signal à bruit d'environ 25dB). De plus, la résolution élevée et le fait que les objets ne soient pas enfouis permettent d'avoir des ombres très reconnaissables qu'un algorithme tels que ceux présentés dans le paragraphe 1.3.3.2 pourra caractériser très facilement. Ces images serviront dans ce mémoire afin de décrire, quand cela s'avérera nécessaire, de façon simple les méthodes de détection proposées, mais elles ne pourront pas servir de qualification de ces méthodes.

Pour cela, nous avons à notre disposition trois jeux de données de résolution plus faible, contenant des objets partiellement ou complètement enfouis. La première image (figure 1.11, image C) est issue de données enregistrées lors de la campagne BMC'99 (*Buried Mine Classification*) par le GESMA en partenariat avec le SACLANTCENTRE (OTAN), avec un sonar fonctionnant dans la bande 14-20 kHz [Hét03]. Elle représente une région d'environ 12 m sur 10 m, avec une définition et une résolution d'environ 10 cm dans les deux dimensions. L'amplitude maximale est approximativement de  $1,8 \cdot 10^4$ . Nous pouvons alors observer assez clairement, au moyen des échos, une mine sphérique à droite (a) posée sur le fond marin. Il y a également des mines enfouies (b, d et e) plus ou moins visibles à l'oeil nu, un rocher (c) et un objet "non identifié" (câble, relief, ... ?) (f) très difficilement visible, avec un faible signal à bruit.

Le deuxième jeu de données (figure 1.12(a), image D) est lui issu de la campagne LFSAS'02 (*Low Frequency SAS*) réalisée dans la Baie de Douarnenez (Finistère) née d'une collaboration entre le GESMA et le TNO-FEL (aujourd'hui TNO *Defence, Security and Safety*, Pays-Bas) [HAZ<sup>+</sup>04, SGC<sup>+</sup>04]. Ces données sont issues d'un sonar de bande de fréquence opérationnelle d'environ 15-25 kHz. L'image représente une région d'environ

40 m sur 20 m avec une taille de pixel de 4 cm environ dans les deux dimensions. La résolution attendue est de l'ordre de 20 cm et l'amplitude maximale de  $2,6 \cdot 10^7$ . On y trouve trois mines sous-marines cylindriques : une posée sur le fond (écho du haut), une partiellement enfouie (aux deux tiers environ) vers le centre et une complètement enfouie (en bas).

Le dernier jeu de données a été enregistré lors de la même campagne que le précédent et représente la même région, mais sous un angle de vue différent (rotation de  $90^\circ$ ) et une taille de pixel de 2 cm environ dans les deux dimensions (figure 1.12(b), image E). L'amplitude maximale est d'environ  $3,9 \cdot 10^7$ . On y retrouve alors les mêmes mines que précédemment, les mines allant de haut en bas dans l'image précédente se retrouvant de droite à gauche sur cette image.

## 1.4.2 Méthodes de détection proposées

L'objectif principal de la thèse a été de développer des méthodes permettant la détection et la localisation des objets présents sur les images sonar. Ces méthodes ont été testées et évaluées sur les données SAS décrites ci-dessus mais elles sont *a priori* tout à fait applicables à des images sonar issues d'autres systèmes acoustiques imageurs pour détecter des objets (mines ou non), de petite taille par rapport à la région balayée, enfouis ou non dans le sédiment marin. Etant destinées à la détection d'objets enfouis, ces méthodes se sont donc basées sur la détection des échos formés par les objets présents sur l'image. Par la suite, les termes "objet" et "écho" seront alors souvent confondus : si on détecte le ou les échos, on a détecté l'objet associé.

Les méthodes présentées dans ce mémoire n'ont pas pour but de "classifier" les objets détectés. Ainsi, des rochers ou d'autres objets de taille comparable seront détectés au même titre que les mines sous-marines. Elles permettront seulement de détecter, et de localiser, les échos susceptibles d'appartenir à un objet recherché. Il est alors suggéré que la reconnaissance de cet objet se fera dans une phase ultérieure.

Dans la suite de ce mémoire, les images sonar seront désignées par leur lettre, tel que ci-dessus (image A, B, C, D ou E). Une connaissance approfondie des images sonar doit être le préalable à tout développement de méthode de détection, et notamment en ce qui concerne les propriétés statistiques au niveau global ou local. Ce sera l'objet des prochains chapitres de ce mémoire.

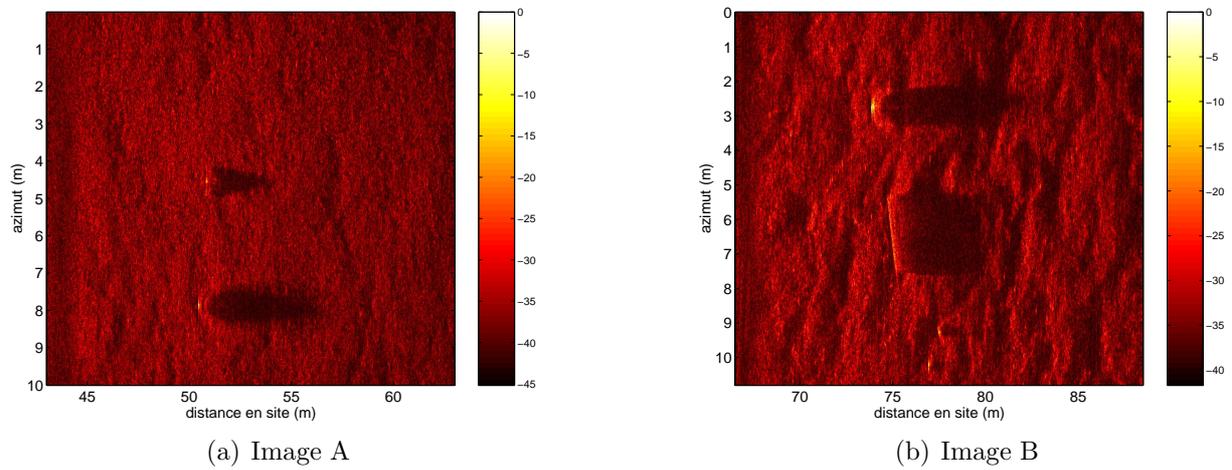


FIG. 1.10 – Images SAS haute résolution.

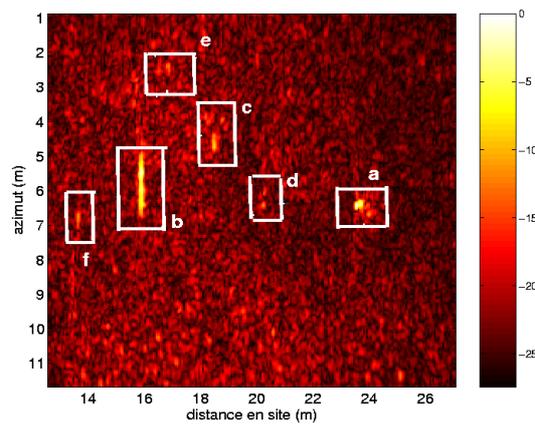


FIG. 1.11 – Image SAS basse résolution : image C.

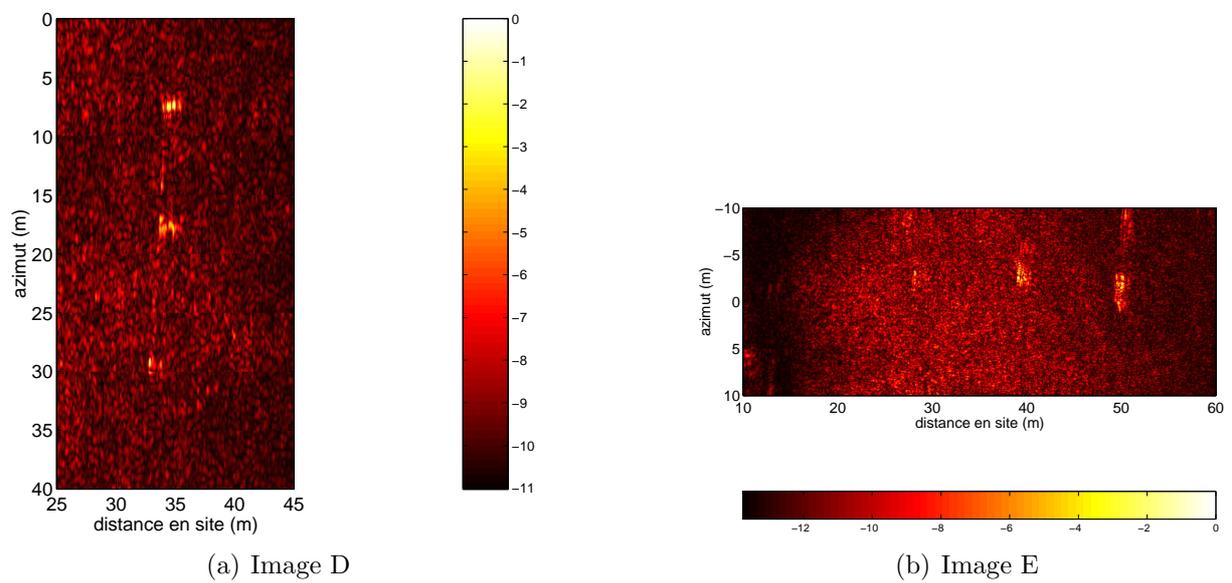


FIG. 1.12 – Images SAS basse résolution.

## Chapitre 2

# Description statistique globale des images sonar

Nous nous intéressons ici à la modélisation statistique des images sonar.

De nombreux modèles statistiques ont été proposés, basés pour la plupart sur les propriétés du bruit de speckle inhérent aux signaux issus de systèmes cohérents. C'est le cas du modèle le plus simple, mais pas toujours approprié, proposé par la loi de Rayleigh. D'autres modèles, non gaussiens, ont été proposés tels que la loi de Weibull ou les lois K.

Ces différents modèles sont testés sur les images SAS présentées dans le premier chapitre et évalués au moyen de critères (distance de Kolmogorov et critère du  $\chi^2$ ).

---

## Sommaire

---

<b>2.1</b>	<b>Introduction</b>	<b>35</b>
<b>2.2</b>	<b>Le bruit de speckle et la loi de Rayleigh</b>	<b>35</b>
2.2.1	Le bruit de speckle	35
2.2.2	Loi de Rayleigh	36
2.2.2.1	Origines et description de la loi	36
2.2.2.2	Estimation du paramètre	38
<b>2.3</b>	<b>Modélisation par des lois non gaussiennes</b>	<b>38</b>
2.3.1	Loi de Weibull	39
2.3.1.1	Description de la loi	39
2.3.1.2	Estimation des paramètres	40
2.3.2	Lois K	41
2.3.2.1	Le modèle de McDaniel et la loi K généralisée	41
2.3.2.2	La loi K simple	42
2.3.2.3	Estimation des paramètres	43
2.3.3	Autres modèles non gaussiens	44
<b>2.4</b>	<b>Comparaison des modèles statistiques</b>	<b>45</b>
2.4.1	Evaluations de la performance des modèles statistiques	45
2.4.1.1	Le test du $\chi^2$	45
2.4.1.2	La distance de Kolmogorov	46
2.4.2	Comparaison sur les données SAS	46

---

## 2.1 Introduction

Dans ce chapitre, nous nous intéressons aux propriétés statistiques des images sonar au niveau global. Pour cela, nous considérons le nombre de pixels associés aux échos comme négligeable vis à vis de la taille de l'image.

Dans un premier temps, nous étudions rapidement les origines et les propriétés du speckle (voir le paragraphe 1.3.2.1). Dans un deuxième temps, nous regardons les différentes modélisations statistiques possibles, gaussiennes et non gaussiennes. Enfin, les principaux modèles statistiques sont testés sur les données SAS à notre disposition.

## 2.2 Le bruit de speckle et la loi de Rayleigh

### 2.2.1 Le bruit de speckle

L'observation des images sonar (figures 1.10, 1.11 et 1.12) nous permet de constater que les petits détails (échos, contours des ombres, ...) sont généralement très difficilement visibles à cause de la présence de bruit qui chahute l'image. Les bruits liés à l'environnement, aux conditions de navigation et au système sonar (bruit électrique) sont généralement faibles, après éventuellement avoir été corrigés. La mauvaise qualité des images est alors due à un défaut inhérent au sonar et plus généralement à tout système d'émission-réception cohérente. Ce bruit de speckle (également appelé chatoiement ou granularité) 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 (grains de sable, petits cailloux, ...) [CTM<sup>+</sup>98]. Chaque diffuseur se comporte alors comme une source émettant une onde, de même fréquence que l'onde émise, mais d'amplitude, de phase et de direction aléatoires. Le récepteur reçoit alors un signal correspondant au résultat de l'interférence constructive ou destructive des ondes réfléchies par les diffuseurs contenus dans la cellule de résolution.

L'intensité de ce bruit de speckle dépend alors de plusieurs facteurs :

- les caractéristiques du système sonar : intensité des ondes émises, fréquences d'émission (influence sur la résolution et la plus ou moins grande pénétration dans le sédiment), taille de l'antenne de réception, éventuellement synthétique (résolution),
- la position du sonar par rapport au fond marin : angle de rasance (résolution)
- la nature du fond marin : rugosité, densité, ...

Si d'un côté nous pouvons connaître assez précisément les caractéristiques du sonar et les conditions de l'enregistrement des données, nous n'avons généralement pas une connaissance précise de la nature du fond marin sur lequel se réfléchissent les ondes acoustiques. Nous serons alors obligés de faire certaines hypothèses, plus ou moins fortes, sur ses caractéristiques avant de proposer un modèle statistique décrivant les propriétés du signal reçu par le sonar.

## 2.2.2 Loi de Rayleigh

### 2.2.2.1 Origines et description de la loi

La modélisation de la formation du speckle la plus utilisée reprend le formalisme de Goodman [Goo76]. Pour cela, nous devons faire certaines hypothèses sur le nombre, la répartition et les dimensions des diffuseurs situés à l'intérieur de la cellule de résolution :

- A 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,
- A l'échelle de la cellule de résolution, si le fond marin est constitué de zones homogènes, les conditions de réflectivité des ondes sont uniformes,
- La distance entre les diffuseurs d'une cellule de résolution et le sonar est très supérieure à la longueur d'onde rétrodiffusée.

Pour la modélisation nous utilisons alors un modèle des points réverbérants qui consiste à discrétiser le fond insonifié en un ensemble de points réverbérants (ou brillants) [Hel98]. Chacun de ces points contribue alors au signal reçu par le sonar sur la cellule de résolution en renvoyant une copie déphasée et atténuée du signal émis. Si l'on note  $N_d$  le nombre de diffuseurs élémentaires contenus dans la cellule de résolution, nous faisons l'hypothèse fondamentale selon laquelle :

$$\lim_{N_d \rightarrow \infty} \frac{\mathcal{V}(N_d)}{\mathcal{M}(N_d)^2} = 0 \quad (2.1)$$

avec  $\mathcal{M}(N_d)$  et  $\mathcal{V}(N_d)$  respectivement la moyenne et la variance du nombre de diffuseurs évaluées sur l'ensemble des cellules de résolution de l'image.

La réponse  $R$  de chaque cellule peut s'écrire :

$$R = \sum_{i=1}^{N_d} a_i \exp(j \cdot \varphi_i) = A \cdot \exp(j \cdot \phi) \quad (2.2)$$

$A$  étant l'amplitude de la réponse sur une cellule de résolution et  $\phi$  la phase ( $j = \sqrt{-1}$ ). Cette réponse peut également se décomposer en partie réelle  $I$  (en phase) et partie imaginaire  $Q$  (en quadrature) :

$$R = I + j \cdot Q \quad (2.3)$$

Sous les hypothèses suivantes, découlant des hypothèses effectuées ci-dessus :

- $a_i$  et  $\varphi_i$  sont des variables aléatoires indépendantes,
- les phases  $\varphi_i$  sont indépendantes entre elles et suivent une loi uniforme sur l'intervalle  $]-\pi, +\pi]$ ,
- le nombre  $N_d$  est suffisamment important ( $N_d \approx \mathcal{M}(N_d)$ ),

le théorème central limite permet de conclure que les variables  $I$  et  $Q$  suivent des lois gaussiennes centrées de variance  $\alpha^2$ .

Ce modèle est celui d'un speckle entièrement développé, où l'on considère qu'il n'y a aucun écho fort prépondérant dans la cellule de résolution. C'est le cas des surfaces

homogènes dites rugueuses. Une surface est considérée comme rugueuse par rapport à la longueur d'onde  $\lambda$  et l'angle d'incidence  $\theta$  lorsque l'écart-type de son élévation  $\sigma_{el}$  vérifie :

$$\sigma_{el} \gg \frac{\lambda}{8 \cos \theta} \quad (2.4)$$

L'amplitude  $A = \sqrt{I^2 + Q^2}$  suit alors une distribution de Rayleigh :

$$\mathcal{R}_A(A) = \frac{A}{\alpha^2} \exp\left(-\frac{A^2}{2\alpha^2}\right); A \geq 0 \quad (2.5)$$

$\alpha$  est alors le paramètre spécifique à la loi de Rayleigh. Ce paramètre d'échelle est lié à la forme de la distribution (figure 2.1). Il correspond en fait à la valeur la plus représentée dans l'échantillon, à la position du maximum de la densité de probabilité.

Cette distribution est parfois appelée "loi du tireur" : si l'on suppose gaussiennes les probabilités pour le tireur, visant le centre de la cible, d'atteindre une certaine abscisse et une certaine ordonnée, la loi associée à la distance par rapport au centre sera une distribution de Rayleigh.

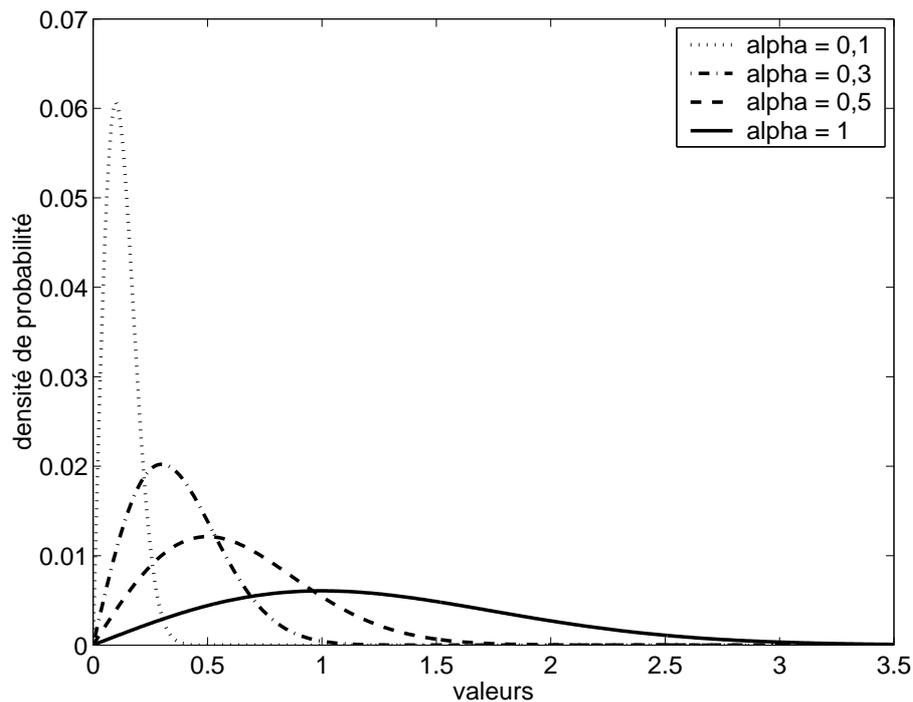


FIG. 2.1 – Lois de Rayleigh pour différentes valeurs du paramètre  $\alpha$ .

Le moment décentré d'ordre  $r$  de  $A$  vérifie alors la relation :

$$\mu'_{A(r)} = (2\alpha^2)^{r/2} \Gamma\left(1 + \frac{r}{2}\right) \quad (2.6)$$

$\Gamma$  étant la fonction Gamma définie par  $\Gamma(z + 1) = z! = \int_0^{+\infty} e^{-t} t^z dt$  pour tout  $z$  réel dans l'intervalle  $]-1, +\infty[$ . Cette formule conduit à une propriété intéressante de la loi de Rayleigh, qui est la relation de proportionnalité entre l'écart-type  $\sigma_A$  et la moyenne  $\mu_A$  de l'amplitude  $A$  :

$$\mu_A = k_R \cdot \sigma_A \quad \text{avec} \quad k_R = \sqrt{\frac{\pi}{4 - \pi}} \approx 1,91 \quad (2.7)$$

Cette relation entre la moyenne et l'écart-type de l'amplitude conduit à décrire le speckle comme un bruit multiplicatif : les fluctuations sont d'autant plus importantes que la réflexion moyenne est forte.

### 2.2.2.2 Estimation du paramètre

Le paramètre  $\alpha$  de la loi de Rayleigh peut être estimé sur les images sonar en utilisant un estimateur par maximum de vraisemblance (MV). En supposant que le minimum des valeurs des pixels de l'image est nul, nous obtenons une estimation du paramètre par la formule, proposée par Mignotte *et al.* [SMCT96, Mig98] :

$$\hat{\alpha}_{MV}^2 = \frac{1}{2N} \sum_{i=1}^N y_i^2 \quad (2.8)$$

avec  $N$  le nombre total de pixels de l'image et  $y_i$  la valeur du pixel  $i$ .

Cet estimateur possède de bonnes propriétés asymptotiques. En effet, on peut montrer qu'il est non biaisé, efficace et consistant [Mig98].

## 2.3 Modélisation par des lois non gaussiennes

La modélisation du bruit de speckle par une loi de Rayleigh, c'est à dire en supposant la gaussianité des composantes réelles et imaginaires de la réponse, précédemment justifiée est classique et modélise assez bien les images sonar. Mais ce modèle n'est pas toujours réaliste expérimentalement lorsqu'on observe une diminution sensible du nombre de diffuseurs par cellule de résolution (la rugosité est alors plus petite devant la longueur d'onde et on peut modéliser le fond par un faible nombre de facettes réfléchissantes). Ce peut également être le cas lorsque la dimension des rugosités du fond devient du même ordre de grandeur que les dimensions de la cellule de résolution. Les enregistrements effectués avec un sonar à antenne synthétique rentrent dans cette catégorie.

Afin de se rapprocher au plus près de la réalité, de nombreux modèles statistiques ont été proposés [AL04] dont beaucoup sont issus de l'imagerie radar [TNTM04]. Certains d'entre eux s'appuient sur des approches physiques (lois de Weibull, K, ...), tandis que d'autres sont basés sur des approches purement mathématiques (log-normal, ...). Dans ce mémoire, nous allons nous concentrer sur deux lois : la loi de Weibull et la loi K (avec une version simple et une version généralisée).

### 2.3.1 Loi de Weibull

#### 2.3.1.1 Description de la loi

La loi de Weibull a pour densité de probabilité [Mig98, CTM<sup>+</sup>98] :

$$\mathcal{W}_A(A) = \frac{\delta}{\beta} \left( \frac{A}{\beta} \right)^{\delta-1} \exp \left\{ - \left( \frac{A}{\beta} \right)^\delta \right\}; A \geq 0 \quad (2.9)$$

$\beta$  est le paramètre d'échelle et  $\delta$  le paramètre de forme, tous les deux définis strictement positifs (figure 2.2). Cette loi est une simple généralisation de la loi de Rayleigh : dans le cas où  $\beta = \sqrt{2}\alpha$  et  $\delta = 2$ , la loi de Weibull se transforme en loi de Rayleigh. Les deux paramètres de la loi de Weibull la rendent alors plus flexible. De même, pour  $\delta = 1$ , on retrouve la loi exponentielle.

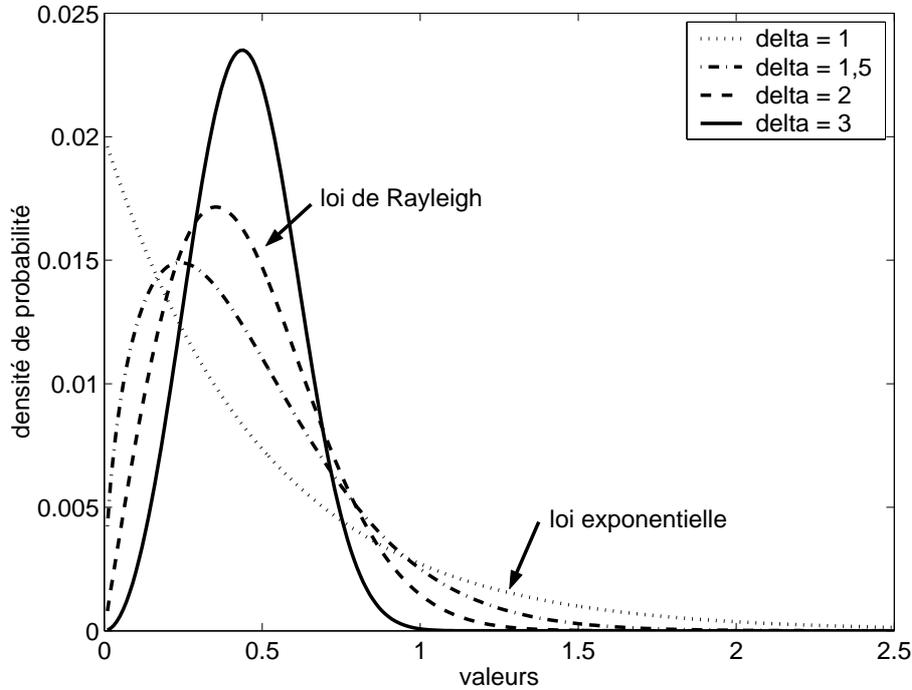


FIG. 2.2 – Lois de Weibull pour différentes valeurs du paramètre  $\delta$  ( $\beta = 0,5$ ).

Cette loi est spécialement adaptée aux images sonar quand on ne connaît pas exactement le comportement du speckle et qu'il peut varier selon les conditions d'expérimentation [MCPB99]. Mais ce modèle est bien adapté seulement dans le cas de faibles hétérogénéités [TNTM04].

Le moment décentré d'ordre  $r$  de  $A$  se calcule selon cette relation :

$$\mu'_{A(r)} = \beta^r \Gamma \left( 1 + \frac{r}{\delta} \right) \quad (2.10)$$

La relation de proportionnalité entre la moyenne et l'écart-type de  $A$  reste alors valable, mais elle dépend cette fois, du paramètre  $\delta$  :

$$\mu_A = k_W(\delta) \cdot \sigma_A \quad (2.11)$$

avec :

$$k_W(\delta) = \frac{\Gamma(1 + 1/\delta)}{\sqrt{\Gamma(1 + 2/\delta) - \Gamma(1 + 1/\delta)^2}} \quad (2.12)$$

Nous pouvons remarquer que pour  $\delta = 2$ , ce qui correspond à la loi de Rayleigh, nous retrouvons la valeur du coefficient  $k_R$  (équation 2.7).

### 2.3.1.2 Estimation des paramètres

Les paramètres  $\beta$  et  $\delta$  peuvent également être estimés en utilisant un estimateur par maximum de vraisemblance, proposé par Mignotte dans sa thèse [CTM<sup>+</sup>98, Mig98]. Nous supposons toujours que le minimum de l'image sonar est nul. L'estimation de  $\delta$  peut alors se faire en utilisant une méthode récursive :

$$\hat{\delta}_{MV} = \lim_{k \rightarrow +\infty} \delta_k \quad (2.13)$$

avec  $\delta_k = F(\delta_{k-1})$ ,  $\delta_0 = 1$  (loi exponentielle) et :

$$F(x) = \frac{N \sum_{i=1}^N y_i^x}{N \sum_{i=1}^N (y_i^x \ln y_i) - \sum_{i=1}^N \ln y_i \sum_{i=1}^N y_i^x} \quad (2.14)$$

En pratique, la convergence est assez rapide et le trentième terme de la suite donne une assez bonne approximation de  $\delta$  (figure 2.3). Un estimateur de  $\beta$  est alors :

$$\hat{\beta}_{MV} = \left( \frac{1}{N} \sum_{i=1}^N y_i^{\hat{\delta}_{MV}} \right)^{1/\hat{\delta}_{MV}} \quad (2.15)$$

On peut montrer que l'estimateur de  $\beta$  possède de bonnes propriétés asymptotiques (non biaisé, efficace et consistant). Par contre, étant donné son expression non explicite, on ne peut pas vérifier les bonnes propriétés asymptotiques de l'estimateur de  $\delta$ . Mais, en toute rigueur, celui donné par le critère du maximum de vraisemblance fait partie des meilleurs estimateurs. On ne peut alors juger de l'efficacité de cet estimateur qu'expérimentalement [Mig98].

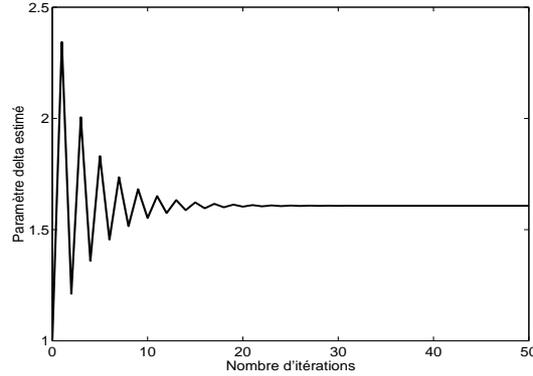


FIG. 2.3 – Variation de l'estimation du paramètre  $\delta$  de la loi de Weibull en fonction du nombre d'itérations.

## 2.3.2 Lois K

### 2.3.2.1 Le modèle de McDaniel et la loi K généralisée

A l'image de la théorie limite (supposant  $N_d$  très grand) aboutissant à la loi de Rayleigh (paragraphe 2.2.2.1), la loi K dérive aussi d'un processus asymptotique selon lequel :

$$\lim_{N_d \rightarrow \infty} \frac{\mathcal{V}(N_d)}{\mathcal{M}(N_d)^2} = \frac{1}{\nu_1} \quad (2.16)$$

avec  $\nu_1$  réel strictement positif.

McDaniel [McD90] propose alors un modèle pour l'intensité  $Y = A^2$  en la décrivant comme le produit de deux variables aléatoires :

$$Y = S.Z \quad (2.17)$$

Cette formule permet d'isoler l'effet du speckle  $Z$  de celui de la réflectivité locale moyenne  $S$ ,  $S$  et  $Z$  suivant chacune une distribution Gamma avec des paramètres différents [GA01] :

$$p_S(S) = \frac{1}{\Gamma(\nu_1)} \frac{\nu_1}{\mu} \left( \frac{\nu_1}{\mu} S \right)^{\nu_1-1} \exp\left(-\frac{\nu_1}{\mu} S\right) \quad (2.18)$$

$$p_Z(Z) = \frac{1}{\Gamma(\nu_0)} \nu_0 (\nu_0 Z)^{\nu_0-1} \exp(-\nu_0 Z) \quad (2.19)$$

avec  $\mu$  et  $\nu_0$  réels strictement positifs.  $\nu_1$  est le paramètre défini par l'équation 2.16.

La densité de probabilité de  $Y$  se calcule alors en utilisant une convolution de Mellin  $\hat{\star}$  [Nic02] :

$$p_Y(Y) = (p_S \hat{\star} p_Z)(Y) = \int_0^{+\infty} p_S(t) p_Z\left(\frac{Y}{t}\right) \frac{dt}{t} = \int_0^{+\infty} p_S\left(\frac{Y}{t}\right) p_Z(t) \frac{dt}{t} \quad (2.20)$$

Nous obtenons alors la densité de probabilité de  $Y$  :

$$p_Y(Y) = \frac{2}{\Gamma(\nu_0)\Gamma(\nu_1)} \frac{\nu_0\nu_1}{\mu} \left(\frac{\nu_0\nu_1}{\mu}Y\right)^{\frac{\nu_1+\nu_0}{2}-1} K_{\nu_1-\nu_0}\left(2\sqrt{\frac{\nu_0\nu_1}{\mu}}Y\right); Y \geq 0 \quad (2.21)$$

$K_\nu$  étant la fonction de Bessel modifiée de deuxième espèce et d'ordre  $\nu$  définie comme :

$$K_\nu(x) = \frac{1}{2} \left(\frac{x}{2}\right)^\nu \int_0^{+\infty} \frac{1}{t^{\nu+1}} \exp\left(-t - \frac{x^2}{4t}\right) dt; x \geq 0 \quad (2.22)$$

La densité de probabilité associée à  $A$  devient alors

$$\mathcal{K}_A^G(A) = \frac{4}{\Gamma(\nu_0)\Gamma(\nu_1)} \sqrt{\frac{\nu_0\nu_1}{\mu}} \left(\sqrt{\frac{\nu_0\nu_1}{\mu}}A\right)^{\nu_0+\nu_1-1} K_{\nu_1-\nu_0}\left(2\sqrt{\frac{\nu_0\nu_1}{\mu}}A\right); A \geq 0 \quad (2.23)$$

Cette distribution est appelée loi K généralisée, une loi à 3 paramètres qui donne un degré supplémentaire de liberté par rapport à la loi de Weibull.  $\nu_1$  est le paramètre de forme,  $\mu$  est le paramètre d'échelle et  $\nu_0$  est un paramètre lié au nombre (supposé) de données brutes moyennées afin de former la réflectivité du pixel sur l'image étudiée [HBL03].

Le moment décentré d'ordre  $r$  de  $A$  se calcule alors selon [Nic02] :

$$\mu'_{A(r)} = \left(\frac{\mu}{\nu_0\nu_1}\right)^{\frac{r}{2}} \frac{\Gamma(\nu_0 + r/2)\Gamma(\nu_1 + r/2)}{\Gamma(\nu_0)\Gamma(\nu_1)} \quad (2.24)$$

La relation de proportionnalité entre la moyenne et l'écart-type de  $A$  reste alors encore valable mais avec un coefficient de proportionnalité dépendant cette fois des deux paramètres  $\nu_0$  et  $\nu_1$  :

$$\mu_A = k_K^G(\nu_0, \nu_1) \cdot \sigma_A \quad (2.25)$$

avec :

$$k_K^G(\nu_0, \nu_1) = \frac{\Gamma(\nu_0 + 1/2)\Gamma(\nu_1 + 1/2)}{\sqrt{\nu_0\nu_1\Gamma(\nu_0)^2\Gamma(\nu_1)^2 - \Gamma(\nu_0 + 1/2)^2\Gamma(\nu_1 + 1/2)^2}} \quad (2.26)$$

### 2.3.2.2 La loi K simple

Etant donnée la complexité de la loi K généralisée, et surtout la difficulté dans l'estimation de trois paramètres (voir le paragraphe suivant), il est souvent proposé d'utiliser plutôt une loi K simplifiée (souvent appelée loi K) provenant de la loi K généralisée en posant  $\nu_0 = 1$ . Ceci revient à considérer la composante "speckle"  $Z$  suivant une loi exponentielle (comme c'est le cas pour la loi de Rayleigh) [Hel98, HBL03].

La densité de probabilité de cette loi K est alors :

$$\mathcal{K}_A(A) = \frac{4}{\Gamma(\nu_1)} \sqrt{\frac{\nu_1}{\mu}} \left( \sqrt{\frac{\nu_1}{\mu}} A \right)^{\nu_1} K_{\nu_1-1} \left( 2 \sqrt{\frac{\nu_1}{\mu}} A \right); A \geq 0 \quad (2.27)$$

avec les mêmes significations pour les paramètres qui ne sont plus qu'au nombre de deux. Si l'on fait tendre  $\nu_1$  vers l'infini, nous obtenons la loi de Rayleigh, ce qui semble logique au vu de l'équation 2.16 qui rejoint alors l'équation 2.1.

De l'équation 2.24, on en déduit le moment décentré d'ordre  $r$  de  $A$  suivant la loi K :

$$\mu'_{A(r)} = \left( \frac{\mu}{\nu_1} \right)^{\frac{r}{2}} \frac{\Gamma(1+r/2)\Gamma(\nu_1+r/2)}{\Gamma(\nu_1)} \quad (2.28)$$

et la relation de proportionnalité :

$$\mu_A = k_K(\nu_1) \cdot \sigma_A \quad (2.29)$$

avec :

$$k_K(\nu_1) = \frac{\Gamma(\nu_1 + 1/2)\sqrt{\pi}}{\sqrt{4\nu_1\Gamma(\nu_1) - \pi\Gamma(\nu_1 + 1/2)^2}} \quad (2.30)$$

Nous pouvons remarquer que pour  $\nu_1 \rightarrow +\infty$  on retrouve le coefficient de proportionnalité de la loi de Rayleigh (équation 2.7).

### 2.3.2.3 Estimation des paramètres

L'estimation des paramètres de la loi K s'avère délicate. En effet, ne pouvant pas exprimer analytiquement la dérivée d'une fonction de Bessel modifiée de deuxième espèce, il n'est pas possible d'utiliser un estimateur par maximum de vraisemblance sans approximation [Nic02]. Cependant, certaines méthodes, ont été proposées afin d'approcher au plus près ce type d'estimateur, souvent en combinant avec une autre méthode plus simple, mais moins précise (méthode des moments) [JPW93, IZB99].

D'autres méthodes, souvent plus simples, existent. Ainsi des méthodes utilisant les statistiques d'ordres supérieurs ou les moments fractionnaires [IZ99] ont été proposées, ainsi que des méthodes récursives [CRB05]. Mais, la méthode d'estimation la plus simple est celle, appelée méthode des moments, qui utilise l'estimation de différents moments statistiques (dont le nombre est au moins égal au nombre de paramètres de la loi) sur l'image pour estimer les paramètres dont ils dépendent.

Pour cela, nous utilisons les formules donnant l'expression des moments de  $A$  en fonction des paramètres des lois K (équations 2.24 et 2.28).

Pour commencer, nous définissons les moments décentrés d'ordre  $r$  estimés sur l'image par la formule :

$$\hat{\mu}'_{A(r)} = \frac{1}{N} \sum_{i=1}^N y_i^r \quad (2.31)$$

les termes ayant les mêmes définitions que dans les paragraphes précédents.

Une estimation du paramètre  $\mu$  peut alors être donnée par :

$$\hat{\mu} = \hat{\mu}'_{A(2)} \quad (2.32)$$

Concernant la loi K simple, on peut facilement trouver un estimateur de  $\nu_1$  par la formule :

$$\hat{\nu}_1 = \frac{2\hat{\mu}'_{A(2)}{}^2}{\hat{\mu}'_{A(4)} - 2\hat{\mu}'_{A(2)}{}^2} \quad (2.33)$$

Ainsi, à partir de l'estimation de deux moments statistiques (ordres 2 et 4), nous pouvons avoir une estimation des deux paramètres de la loi K.

Pour la loi K généralisée, nous aurons besoin d'un moment supplémentaire. Nicolas [Nic02] propose alors de définir deux grandeurs :

$$\begin{aligned} M_4 &= \frac{1}{\mu'_{A(2)}} \frac{\mu'_{A(4)}}{\mu'_{A(2)}} = \frac{(\nu_0+1)(\nu_1+1)}{\nu_0\nu_1} \\ M_6 &= \frac{1}{\mu'_{A(2)}} \frac{\mu'_{A(6)}}{\mu'_{A(4)}} = \frac{(\nu_0+2)(\nu_1+2)}{\nu_0\nu_1} \end{aligned} \quad (2.34)$$

Ainsi, à partir des estimés de  $M_4$  et  $M_6$  obtenus à partir des estimés des moments décentrés d'ordres 2, 4 et 6 (équation 2.31), nous obtenons un système de deux équations à deux inconnues. Si nous notons  $\hat{M}_4$  et  $\hat{M}_6$  les estimées de  $M_4$  et  $M_6$ , et si nous posons  $\hat{M}'_4 = \hat{M}_4 - 1$  et  $\hat{M}'_6 = (\hat{M}_6 - 1)/2$ , nous pouvons montrer que les estimées  $\hat{\nu}_0^G$  et  $\hat{\nu}_1^G$  de  $\nu_0$  et  $\nu_1$  pour la loi K généralisée sont les racines du polynôme du second degré en  $x$  suivant [Nic02] :

$$P(x) = (\hat{M}'_6 - \hat{M}'_4)x^2 + (\hat{M}'_6 - 2\hat{M}'_4)x + 1 \quad (2.35)$$

Il n'est alors pas possible de séparer  $\hat{\nu}_0^G$  et  $\hat{\nu}_1^G$ , qui sont deux solutions d'une équation du second degré : ceci se déduit directement de la forme analytique de la loi K généralisée (équation 2.23), sachant par ailleurs, que  $K_{\nu_1-\nu_0}(x) = K_{\nu_0-\nu_1}(x)$  pour tout  $x$ . Concrètement, nous allons lors de l'estimation choisir pour  $\hat{\nu}_0^G$  la valeur la plus proche de 1 au vu des définitions que l'on a données des paramètres  $\nu_0$  et  $\nu_1$  de la loi, et de l'approximation faite pour la loi K simple.

Ces estimateurs n'étant pas issus d'un critère de maximum de vraisemblance, ils ne sont pas *a priori* les plus efficaces. Nous pouvons cependant évaluer leurs variances [Nic02] que nous n'allons pas, par souci de concision, développer dans ce mémoire. Nous pouvons cependant dire que ces variances sont corrélées les unes aux autres, ce qui pose problème dans l'estimation quand les deux paramètres ont des valeurs proches. Ceci explique en partie l'utilisation d'une loi K simplifiée, en fixant l'un de ces paramètres.

### 2.3.3 Autres modèles non gaussiens

D'autres loi non-gaussiennes ont été proposées pour modéliser l'amplitude des pixels des images sonar. La plupart d'entre elles sont communes avec l'imagerie radar et s'appuient

seulement sur des approches mathématiques. On peut citer parmi elles la loi log-normale qui est spécialement adaptée au milieu hétérogène [TNTM04]. Nous pouvons également citer les lois de Rice (Nagakami-Rice ou Rayleigh-Rice) qui prend en compte la présence de réflecteurs de forte intensité dans un milieu homogène [Kes02]. Mais ces lois de Rice ne sont pas adaptées à notre problème qui consiste à séparer les échos (d'amplitude plutôt élevée) du milieu. Toutes ces lois ont deux paramètres.

Parmi les lois à trois paramètres, outre la loi K présentée plus haut, nous pouvons citer la loi de Fisher qui est jusque là assez peu utilisée et essentiellement en imagerie radar [Nic03].

Une autre catégorie de modélisation statistique vient du mélange de lois. Ainsi, en imagerie sonar, le mélange de lois de Rayleigh connaît un assez bon succès [GA01, HKHC03]. Mais l'estimation des différents paramètres de ces lois et des coefficients de pondération peut s'avérer très rapidement fastidieux.

Des modèles prennent en compte la corrélation entre les signaux rétrodiffusés par des zones voisines du fond [Hel98]. Mais le calcul du coefficient de corrélation complique sérieusement le modèle.

Ces modèles statistiques ont tous leur intérêt et sont parfaitement adaptés pour certaines applications (analyse des fonds marins entre autres), mais ils n'ont pas été retenus pour être développés dans ce mémoire par soucis de simplification. De plus, nous allons voir dans le paragraphe suivant que les modèles décrits plus en détails plus haut ont fait preuve de leur efficacité pour notre application.

## 2.4 Comparaison des modèles statistiques

Dans ce paragraphe, nous allons évaluer les performances des modèles statistiques présentés ci-dessus sur des images SAS aux caractéristiques différentes.

### 2.4.1 Evaluations de la performance des modèles statistiques

Afin d'évaluer la performance de chacun de ces modèles, nous nous munissons de deux grandeurs permettant de juger de la ressemblance d'une loi empirique (correspondant, dans notre application de traitement d'images, à l'histogramme normalisé) à une loi théorique supposée adéquate (ou loi estimée pour notre application) [Sap90].

#### 2.4.1.1 Le test du $\chi^2$

Si l'on note  $k_i$  le nombre de réalisations et  $p_i$  la probabilité estimée de la valeur  $i$ , la distance de  $\chi^2$  est définie comme :

$$d_{\chi^2} = \sum_{i=1}^{n_{\text{val}}} \frac{(k_i - Np_i)^2}{Np_i} \quad (2.36)$$

avec  $n_{\text{val}}$  le nombre des valeurs (niveaux de gris) possibles et  $N$  le nombre d'observations (la taille de l'image en pixels dans notre cas).

On peut montrer que quand le nombre d'observations  $N$  tend vers l'infini, si les échantillons suivent bien la loi estimée, cette distance tend vers une distribution du  $\chi^2$  à  $n_{\text{val}}$  degrés de libertés. Le test consiste alors à rejeter la loi estimée si la distance définie ci-dessus a une valeur qui n'a qu'une faible probabilité d'être dépassée par une variable aléatoire  $\chi^2$  à  $n_{\text{val}}$  degrés de liberté. Dans ce mémoire, nous n'allons pas pratiquer ce test, le nombre de degrés de liberté étant trop importante (images codées sur plusieurs milliers de niveaux de gris) : nous allons nous contenter d'utiliser la distance pour comparer les performances de modélisation des différentes lois sur les images.

#### 2.4.1.2 La distance de Kolmogorov

Une autre mesure de distance permettant d'évaluer la qualité d'un modèle statistique est la distance variationnelle de Kolmogorov. Si on note  $k'_i$  le nombre de réalisations des valeurs 1 à  $i$  et  $p'_i$  la valeur en  $i$  de la fonction de répartition associée à  $p_i$ , cette distance se définit par la relation :

$$d_K = \max_{i=1 \dots N_{\text{val}}} |k'_i - Np'_i| \quad (2.37)$$

Bien entendu, ces critères sont d'autant plus faibles que la modélisation statistique des données est bonne.

### 2.4.2 Comparaison sur les données SAS

Dans ce paragraphe, nous allons évaluer les performances de chacun des modèles statistiques développés dans les parties 2.2 et 2.3 sur les images sonar A (figure 1.10(a)), C (figure 1.11) et D (figure 1.12(a)) présentées dans le premier chapitre de ce mémoire. Pour cela, nous estimons sur chacune des images les paramètres des lois de Rayleigh, de Weibull, K et K généralisée. Nous superposons alors les lois ainsi estimées sur l'histogramme (normalisé) de chacune des images afin de pouvoir évaluer qualitativement la performance des modèles (figures 2.4, 2.5 et 2.6). Nous calculons également les critères présentés dans le paragraphe précédent pour chacune des lois, afin d'avoir une évaluation quantitative des performances des unes par rapport aux autres (après normalisation pour avoir des résultats indépendants de la taille des images, tableaux 2.1, 2.2 et 2.3).

Notons que sur l'image A, l'ombre projetée par l'objet a une taille assez importante et ne peut donc pas être négligée. Le signal présent dans cette région est essentiellement d'origine électronique et son amplitude est alors le plus souvent modélisée par une distribution gaussienne. Le modèle conduisant à la loi de Rayleigh reste donc valide (en faisant rentrer ce signal dans le terme  $I$  de l'équation 2.3).

En observant autant les figures que les valeurs des critères du  $\chi^2$  et de Kolmogorov, nous avons la confirmation de la mauvaise modélisation des données effectuée par la loi de Rayleigh. Nous pouvons cependant remarquer que la distribution de Rayleigh est mieux

adaptée aux images C et D qu'à l'image A (regarder les figures et les valeurs du critère du  $\chi^2$ ). Ceci confirme le fait que la loi de Rayleigh est mieux adaptée à des images de faible résolution (voir le paragraphe 2.2).

Nous pouvons également remarquer que la loi de Weibull permet alors une meilleure modélisation, et que les lois K décrivent encore mieux les données. C'est surtout le cas de la loi K généralisée dont les trois paramètres permettent d'approcher très efficacement les lois empiriques (histogrammes) que suivent les données. Cependant, les écarts entre ces lois sont moindres qu'avec la loi de Rayleigh et les différences se font essentiellement au niveau de la "tête" (région de la distribution de densités de probabilité élevées) des distributions, les courbes au niveau de la "queue" étant assez proches les unes des autres. Etant donné que notre but est de séparer les pixels liés au fond bruité de ceux appartenant aux échos, ayant *a priori* des valeurs plus élevées que la moyenne du fond, la bonne modélisation de cette "queue" de distribution est ce qui nous intéresse au premier chef. Ceci sera mis en lumière dans le prochain chapitre.

Nous pouvons alors conclure que la modélisation par une loi de Rayleigh sera à éviter par la suite au vu de la mauvaise qualité de cette modélisation. Pour le choix parmi les autres lois, il devra se faire selon un compromis entre l'efficacité de la modélisation et la complexité de l'estimation des paramètres. Ceci se fera selon l'application.

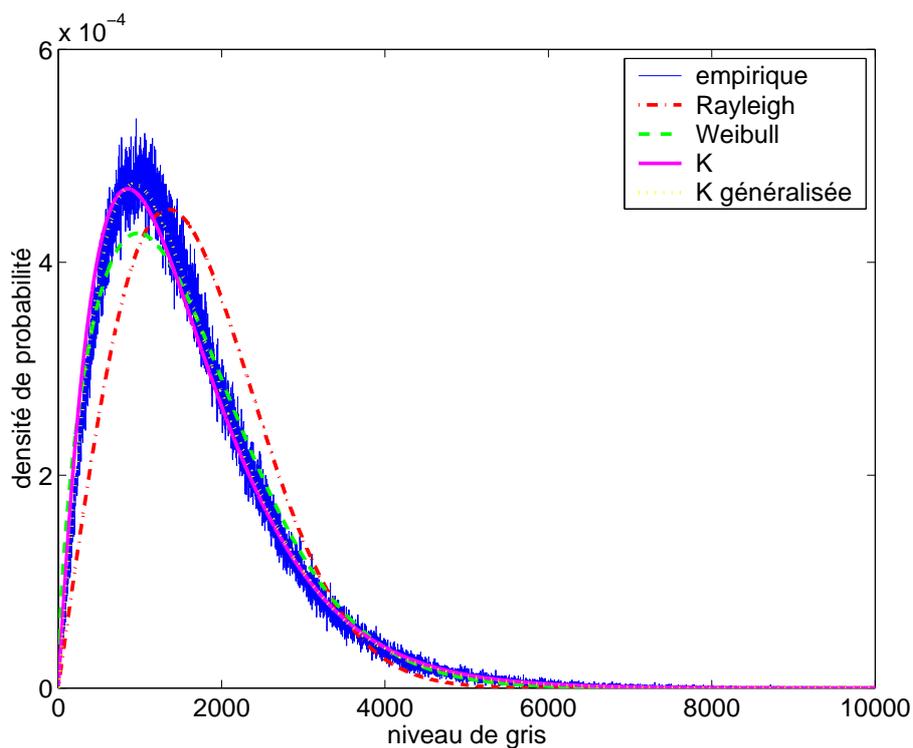


FIG. 2.4 – Modèles estimés sur l'image A.

TAB. 2.1 – Comparaison des performances des différents modèles statistiques sur l'image A.

Distribution	Paramètres estimés	Critères	
		Critère du $\chi^2$	Distance de Kolmogorov
Rayleigh	$\hat{\alpha}_{MV} \approx 1348,7$	3049,7	$1,61 \cdot 10^{-4}$
Weibull	$\hat{\beta}_{MV} \approx 1784,8$ $\hat{\delta}_{MV} \approx 1,607$ (50 itérations)	0,204	$1,08 \cdot 10^{-4}$
K	$\hat{\mu} \approx 3,638 \cdot 10^6$ $\hat{\nu}_1 \approx 1,772$	0,0155	$8,40 \cdot 10^{-5}$
K généralisée	$\hat{\mu} \approx 3,638 \cdot 10^6$ $\hat{\nu}_0^G \approx 1,060$ $\hat{\nu}_1^G \approx 1,996$	0,0073	$6,20 \cdot 10^{-5}$

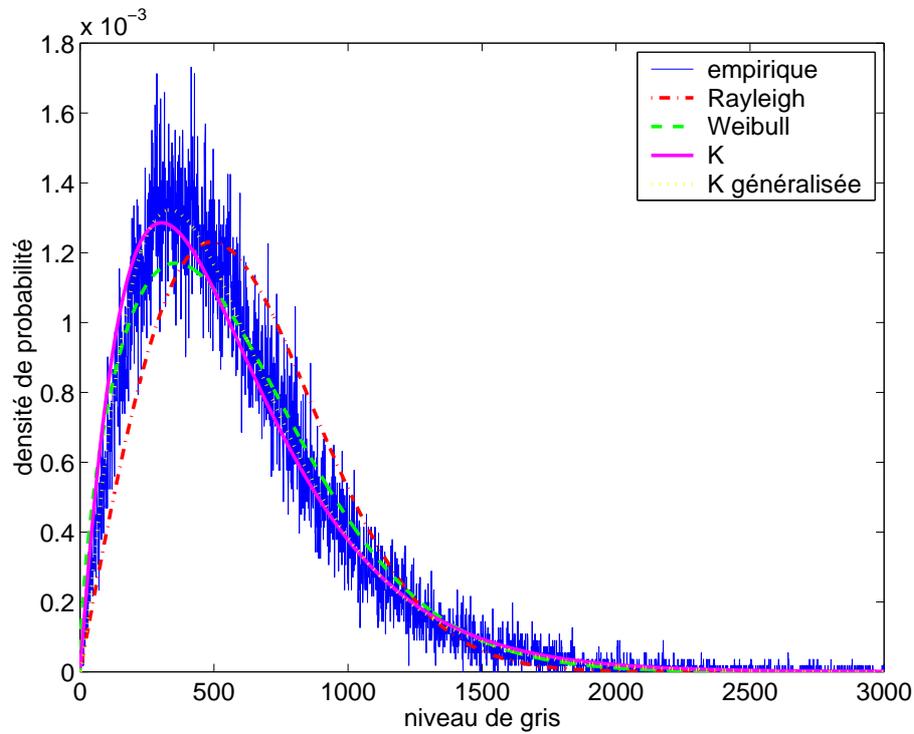


FIG. 2.5 – Modèles estimés sur l'image C.

TAB. 2.2 – Comparaison des performances des différents modèles statistiques sur l'image C.

Distribution	Paramètres estimés	Critères	
		Critère du $\chi^2$	Distance de Kolmogorov
Rayleigh	$\hat{\alpha}_{MV} \approx 492,7$	44,69	$7,15 \cdot 10^{-4}$
Weibull	$\hat{\beta}_{MV} \approx 652,4$ $\hat{\delta}_{MV} \approx 1,612$ (50 itérations)	0,301	$5,75 \cdot 10^{-4}$
K	$\hat{\mu} \approx 4,856 \cdot 10^5$ $\hat{\nu}_1 \approx 1,699$	0,0764	$5,19 \cdot 10^{-4}$
K généralisée	$\hat{\mu} \approx 4,856 \cdot 10^5$ $\hat{\nu}_0^G \approx 1,268$ $\hat{\nu}_1^G \approx 1,577$	0,0558	$4,55 \cdot 10^{-4}$

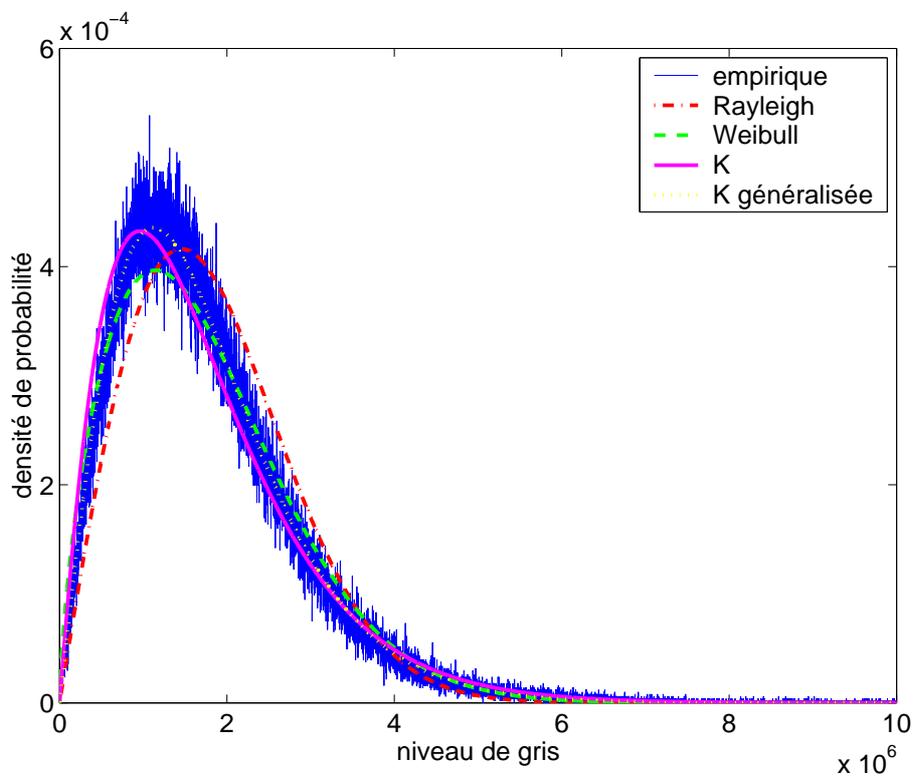


FIG. 2.6 – Modèles estimés sur l'image D.

TAB. 2.3 – Comparaison des performances des différents modèles statistiques sur l'image D.

Distribution	Paramètres estimés	Critères	
		Critère du $\chi^2$	Distance de Kolmogorov
Rayleigh	$\hat{\alpha}_{MV} \approx 1,457 \cdot 10^6$	915,6	$1,58 \cdot 10^{-4}$
Weibull	$\hat{\beta}_{MV} \approx 1,960 \cdot 10^6$ $\hat{\delta}_{MV} \approx 1,679$ (50 itérations)	0,978	$1,43 \cdot 10^{-4}$
K	$\hat{\mu} \approx 4,248 \cdot 10^{12}$ $\hat{\nu}_1 \approx 1,957$	0,0446	$1,34 \cdot 10^{-4}$
K généralisée	$\hat{\mu} \approx 4,248 \cdot 10^{12}$ $\hat{\nu}_0^G \approx 1,011$ $\hat{\nu}_1^G \approx 3,197$	0,0166	$1,04 \cdot 10^{-4}$

## Chapitre 3

# Description statistique locale des images sonar

Nous décrivons les images sonar au niveau local, c'est-à-dire quand on regarde l'image au travers d'une fenêtre composée d'un nombre limité de pixels par rapport à la taille de l'image complète.

Les propriétés statistiques qui en découlent sont alors mises en évidence par une représentation moyenne/écart-type. Cette représentation permet de projeter les données dans un repère conduisant à une séparation des pixels associés aux échos de ceux correspondant au fond. Une segmentation de l'image sonar basée sur cette représentation peut alors être réalisée.

Une automatisation de cette méthode de segmentation est proposée utilisant un critère d'entropie évalué sur l'image segmentée. Ainsi le seuil est réglé automatiquement en considérant les variations d'entropie obtenus. La méthode proposée est ensuite évaluée qualitativement et quantitativement (au moyen de courbes COR) sur les données sonar réelles aux propriétés différentes.

---

**Sommaire**


---

<b>3.1</b>	<b>Introduction</b>	<b>53</b>
<b>3.2</b>	<b>Relation entre la moyenne et l'écart-type au niveau local</b>	<b>53</b>
3.2.1	Modélisation statistique des images sonar au niveau local	53
3.2.2	Relation entre la moyenne et l'écart-type	54
<b>3.3</b>	<b>Représentation moyenne / écart-type</b>	<b>56</b>
3.3.1	Construction de la représentation moyenne/écart-type	56
3.3.1.1	Schéma de construction	56
3.3.1.2	Performances des estimateurs	58
3.3.1.3	Choix de la fenêtre de calcul	58
3.3.2	Interprétation de la représentation	59
3.3.2.1	Relation de proportionnalité du fond bruité	59
3.3.2.2	Modèle statistique local	59
3.3.3	Liens avec l'image sonar	60
<b>3.4</b>	<b>Segmentation automatique des images sonar</b>	<b>61</b>
3.4.1	Principe de la méthode de segmentation	61
3.4.2	Automatisation de la segmentation	62
3.4.2.1	Principe de l'automatisation	62
3.4.2.2	Choix du critère d'arrêt	63
3.4.2.3	Choix du seuil de la segmentation	64
<b>3.5</b>	<b>Application aux données SAS</b>	<b>66</b>
3.5.1	Evaluation des performances	66
3.5.2	Segmentation des images SAS	67
<b>3.6</b>	<b>Bilan</b>	<b>78</b>

---

## 3.1 Introduction

Dans le chapitre précédent, nous avons cherché un modèle statistique adapté à la description globale de l'image qui est essentiellement composée de pixels du fond marin bruité par du speckle. Dans ce chapitre, nous décrivons les images sonar au niveau local, c'est-à-dire quand on regarde l'image au travers d'une fenêtre composée d'un nombre limité de pixels par rapport à la taille de l'image complète.

Pour cela, nous allons tout d'abord étudier les propriétés statistiques des images sonar au niveau local. Nous allons ensuite présenter la construction et les propriétés de la représentation moyenne / écart-type. Enfin, nous allons proposer une méthode de segmentation basée sur celle-ci et automatisée à partir d'un critère d'entropie. Cette méthode sera testée et évaluée qualitativement et quantitativement sur les images sonar présentées dans le chapitre 1.

## 3.2 Relation entre la moyenne et l'écart-type au niveau local

### 3.2.1 Modélisation statistique des images sonar au niveau local

Dans le chapitre précédent, nous avons supposé que le nombre de pixels associés aux échos était négligeable en comparaison avec la taille de l'image. Nous avons pu ainsi obtenir des modèles statistiques décrivant l'image dans son ensemble, à partir d'hypothèses faites sur la structure du fond marin.

Dans ce chapitre, nous considérons une fenêtre, composée d'un nombre limité de pixels (quelques dizaines) qui balaye toute l'image sonar. L'approximation faite précédemment n'est alors plus valable : sur une fenêtre, certains pixels sont associés au fond bruité et d'autres, potentiellement, à un écho. Les proportions de chacun de ces pixels varient d'une fenêtre à l'autre. De plus, la proportion de pixels associés à un écho peut être plus élevée que celle des pixels du fond.

Nous définissons alors la grandeur  $p$  comme étant la proportion de pixels appartenant à un écho dans la fenêtre considérée (figure 3.1).  $p$  peut alors varier entre 0 et 1.  $(1 - p)$  est alors la proportion de pixels associés au fond bruité.

Nous supposons que les pixels associés au fond dans la fenêtre considérée suivent le même modèle statistique que l'image sonar au niveau global. Etant donné le faible nombre de pixels associés aux échos, il est très difficile de modéliser leurs valeurs en utilisant une variable aléatoire suivant une loi statistique. De plus, si l'on considère un seul écho, il est composé de pixels de valeurs comprises dans un intervalle restreint. On considère alors ces pixels comme des éléments déterministes d'amplitude  $D$ .

En supposant que sur une fenêtre, les pixels associés à un écho appartiennent au même écho d'amplitude  $D$ , nous pouvons alors définir un rapport signal à bruit (RSB)  $\rho$  selon la formule :

$$\rho = \frac{D - \mu_B}{\sigma_B} \quad (3.1)$$

avec  $\mu_B$  et  $\sigma_B$  respectivement la moyenne et l'écart-type des pixels associés au fond bruité. L'amplitude des échos étant généralement plus élevée que la moyenne des valeurs du fond bruité (même si certaines de ces valeurs du bruit peuvent être plus élevées que l'amplitude de l'écho),  $\rho$  est supposé strictement positif. En utilisant l'hypothèse précédemment faite sur le bruit, et les relations de proportionnalité décrites dans le chapitre précédent (équations 2.7, 2.11, 2.25 et 2.29), cette définition peut s'écrire :

$$\rho = \frac{D}{\sigma_B} - k \quad (3.2)$$

$k$  étant le coefficient de proportionnalité entre la moyenne et l'écart-type des pixels du fond (voir son calcul, selon le modèle statistique choisi, dans le chapitre 2).

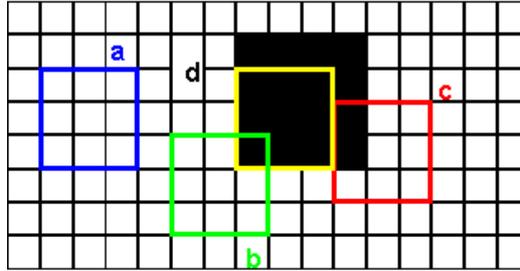


FIG. 3.1 – Modèle d'un écho et différentes valeurs du paramètre  $p$  :  
 (a, fenêtre bleue)  $p = 0$ , (b, verte)  $p = 1/9$ ,  
 (c, rouge)  $p = 2/9$ , (d, jaune)  $p = 1$ ,  
 pixels noirs = région déterministe (écho), pixels blancs = fond bruité.

### 3.2.2 Relation entre la moyenne et l'écart-type

Maintenant que les hypothèses sur la nature des éléments composant l'image sonar ont été faites, et les différentes grandeurs définies, nous allons chercher à établir une relation entre la moyenne  $\mu_F$  et l'écart-type  $\sigma_F$  des valeurs de l'ensemble des pixels de la fenêtre glissante.

Ainsi, d'après les hypothèses faites dans le paragraphe précédent, et en notant  $\mu'_{D(r)}$ ,  $\mu'_{B(r)}$  et  $\mu'_{F(r)}$  les moments décentrés d'ordre  $r$  de, respectivement, la 'partie "écho"', la partie "fond" et l'ensemble de la fenêtre, nous avons la relation :

$$\mu'_{F(r)} = p \cdot \mu'_{D(r)} + (1 - p) \cdot \mu'_{B(r)} \quad (3.3)$$

Si nous considérons  $\mu_X = \mu'_{X(1)}$  et  $\sigma_X^2 = \mu'_{X(2)} - \mu'^2_{X(1)}$  respectivement la moyenne et la variance de la variable  $X$  ( $X$  peut être remplacée par  $D$ ,  $B$  ou  $F$ ), nous avons :

$$\mu_F = p \cdot \mu_D + (1 - p) \cdot \mu_B \quad (3.4)$$

$$\sigma_F^2 + \mu_F^2 = p(\sigma_D^2 + \mu_D^2) + (1 - p)(\sigma_B^2 + \mu_B^2) \quad (3.5)$$

Or, si nous tenons compte des hypothèses faites sur la nature des échos, nous avons :

$$\mu'_{D(r)} = D^r \quad (3.6)$$

ce qui conduit à :

$$\mu_D = D \quad \text{et} \quad \sigma_D = 0 \quad (3.7)$$

et par conséquent :

$$\mu_F = \mu_B + p(D - \mu_B) \quad (3.8)$$

$$\sigma_F^2 + \mu_F^2 = \sigma_B^2 + \mu_B^2 + p(D^2 - \sigma_B^2 - \mu_B^2) \quad (3.9)$$

En utilisant la définition du RSB (équation 3.1) et la proportionnalité entre  $\mu_B$  et  $\sigma_B$ , nous obtenons :

$$\mu_F = k\sigma_B + p\rho\sigma_B \quad (3.10)$$

$$\sigma_F^2 + \mu_F^2 = (1 + k^2)\sigma_B^2 + p(\rho^2 + 2k\rho - 1)\sigma_B^2 \quad (3.11)$$

En combinant ces deux relations (la première nous permettant d'exprimer  $p$  que l'on injecte dans la deuxième), nous aboutissons à une relation intéressante entre  $\sigma_F$  et  $\mu_F$  :

$$\sigma_F^2 + \mu_F^2 = \frac{1}{\rho}(\rho^2 + 2k\rho - 1)\sigma_B\mu_F + \frac{1}{\rho}(\rho + k)(1 - k\rho)\sigma_B^2 \quad (3.12)$$

Nous pouvons remarquer que cette équation reste valide dans les cas limites : si  $p = 0$  (la fenêtre ne contient que des pixels associés au fond bruité),  $\mu_F = \mu_B = k\sigma_B$  et  $\sigma_F = \sigma_B$  ; si  $p = 1$  (la fenêtre ne contient que des pixels appartenant à un écho),  $\mu_F = D = (\rho + k)\sigma_B$  et  $\sigma_F = 0$ .

Nous avons alors dans le repère moyenne/écart-type des valeurs des pixels contenus dans la fenêtre (en faisant varier  $p$  entre 0 et 1) des arcs d'ellipses partant tous (pour un  $\sigma_B$  donné) d'un point  $(\sigma_B, \mu_B)$  (correspondant à  $p = 0$ ) et tendant vers la valeur  $D = (\rho + k)\sigma_B$  pour un écart-type tendant vers zéro (correspondant à  $p = 1$ ) (figure 3.2).

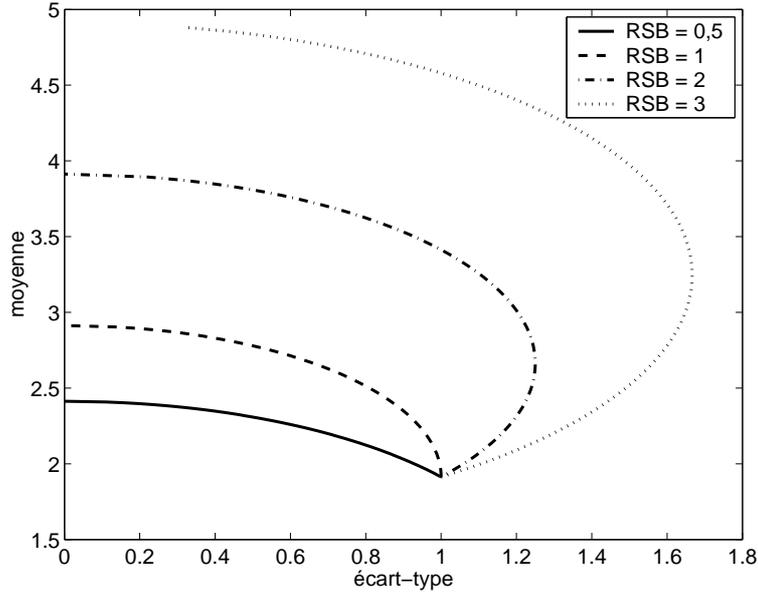


FIG. 3.2 – Moyenne en fonction de l'écart-type des valeurs des pixels d'une fenêtre pour différents RSB ( $\sigma_B = 1$ ,  $k = k_R \approx 1,91$ ).

### 3.3 Représentation moyenne / écart-type

Le paragraphe précédent nous a montré l'intérêt de la moyenne et de l'écart-type, évalués sur une fenêtre glissante, dans l'analyse des images sonar. En effet, d'après la relation 3.12, les valeurs de ces grandeurs, et surtout le lien entre elles, dépendent de la présence ou non d'un élément déterministe (écho) et de ses propriétés.

#### 3.3.1 Construction de la représentation moyenne/écart-type

##### 3.3.1.1 Schéma de construction

L'idée est alors de représenter l'image sonar dans un nouvel espace permettant de mettre en évidence les propriétés des moyennes et des écart-types évalués localement. On obtiendra alors une représentation moyenne / écart-type de l'image.

Inspirée de l'espace des caractéristiques utilisé pour la segmentation de spectrogrammes [Hor02, HMC02], cette représentation correspond à une projection de l'image dans un repère avec l'écart-type en abscisses et la moyenne en ordonnées. Pour construire cette représentation, on fait glisser une fenêtre carrée sur toute l'image (en effectuant un recouvrement complet), le pixel courant étant au centre. Pour chaque pixel, l'écart-type  $\hat{\sigma}_F$  et la moyenne  $\hat{\mu}_F$  sont estimés sur la fenêtre selon ces relations :

$$\hat{\mu}_F = \frac{1}{n} \sum_{i=1}^n y_i \quad (3.13)$$

$$\hat{\sigma}_F = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{\mu}_F)^2} \quad (3.14)$$

avec  $n$  le nombre de pixels de la fenêtre de calcul et  $y_i$  la valeur du pixel  $i$  de la fenêtre. Le couple  $(\hat{\sigma}_F, \hat{\mu}_F)$  correspond alors aux coordonnées du représentant du pixel courant dans le repère moyenne / écart-type (figure 3.3).

La figure 3.4(b) montre la représentation moyenne / écart-type d'une partie de l'image A (figure 1.10(a)) correspondant à une région contenant la mine de type "rockan" (figure 3.4(a)), construite avec une fenêtre de taille  $5 \times 5$ . Nous verrons une interprétation de cette figure dans le paragraphe 3.3.2.

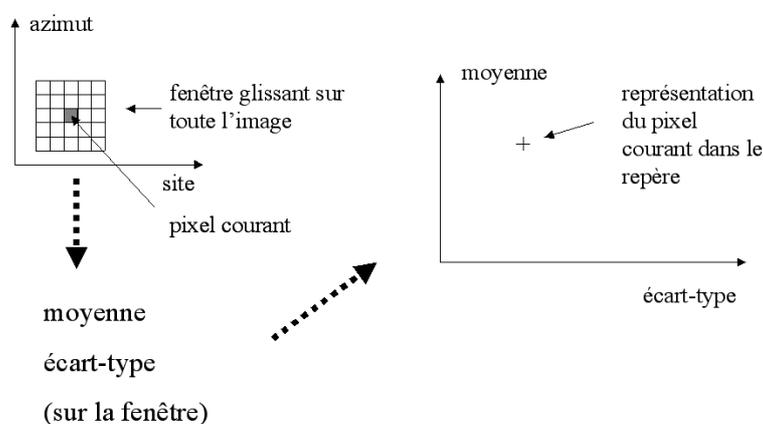


FIG. 3.3 – Construction d'une représentation moyenne / écart-type.

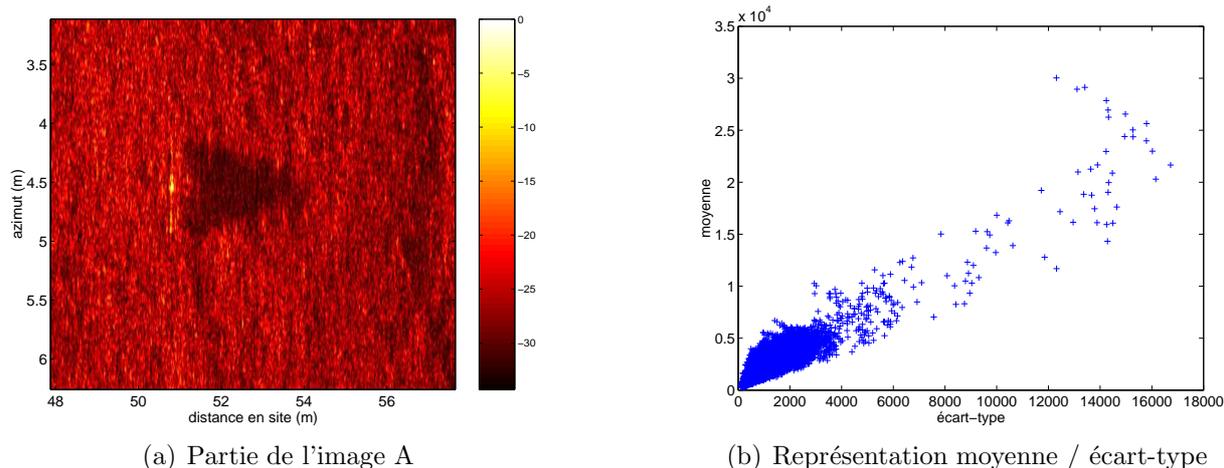


FIG. 3.4 – Représentation moyenne / écart-type d'une partie de l'image A.

### 3.3.1.2 Performances des estimateurs

Afin d'évaluer la performance des estimateurs, nous pouvons calculer leurs moments [KS63].

En ce qui concerne l'estimateur de la moyenne  $\hat{\mu}_F$ , la moyenne  $\mathcal{M}(\hat{\mu}_F)$  et la variance  $\mathcal{V}(\hat{\mu}_F)$  sont :

$$\mathcal{M}(\hat{\mu}_F) = \mu_F \quad (3.15)$$

$$\mathcal{V}(\hat{\mu}_F) = \frac{\sigma_F^2}{n} \quad (3.16)$$

L'estimateur de la moyenne est alors non biaisé et consistant, avec une variance variant en  $1/n$ .

Pour l'estimateur de l'écart-type, la moyenne  $\mathcal{M}(\hat{\sigma}_F)$  et la variance  $\mathcal{V}(\hat{\sigma}_F)$  sont donnés par :

$$\mathcal{M}(\hat{\sigma}_F) \approx \frac{1}{n} \frac{\sqrt{(4n^2 - 3n - 3)\sigma_F^4 - (n-1)\mu_{F(4)}}}{\sigma_F} \quad (3.17)$$

$$\mathcal{V}(\hat{\sigma}_F) \approx \frac{1}{4n^2} \frac{(n-1)\mu_{F(4)} - (n-3)\sigma_F^4}{\sigma_F^2} \quad (3.18)$$

avec  $\mu_{F(4)}$  le moment centré d'ordre 4 des valeurs des pixels de la fenêtre de calcul. Ces relations proviennent de l'approximation  $\mathcal{V}(\sqrt{X}) \approx \frac{\mathcal{V}(X)}{4\mathcal{M}(X)}$  pour  $X$  variable aléatoire [KS63]. Cet estimateur est donc asymptotiquement non biaisé et est consistant avec une variance variant en  $1/n$ .

### 3.3.1.3 Choix de la fenêtre de calcul

Le choix de la taille de la fenêtre de calcul doit se faire selon un compromis entre deux limites. La première est la variance des estimateurs qui est élevée pour de faibles valeurs de  $n$  (équations 3.16 et 3.18). Ceci donne une impression d'éparpillement des représentants des pixels dans le repère moyenne / écart-type (figure 3.5(a)). La deuxième limite se situe quand  $n$  est trop élevé, les échos étant des éléments de petites dimensions, les proportions  $p$  d'éléments déterministes dans la fenêtre de calcul restent à des valeurs faibles et les échos sont noyés dans le fond bruité (équation 3.12, figure 3.5(c)). De plus, dans ce cas, une fenêtre pourrait contenir plusieurs échos et empêcherait de les séparer. La taille de la fenêtre doit alors être choisie assez proche de la taille des échos recherchés afin d'obtenir des valeurs de  $p$  proches de 1.

Nous avons choisi dans ce mémoire d'utiliser des fenêtres carrées, les images sonar utilisées n'ayant pas *a priori* de direction privilégiée. De plus, les calculs s'effectuent avec un recouvrement total d'un pixel à l'autre et, dans chaque fenêtre, aucun pixel n'est privilégié lors des calculs des moyenne et écart-type. Un recouvrement partiel et une pondération de ces pixels permettraient de diminuer légèrement les variances des estimateurs. Mais le gain étant assez limité, nous avons choisi de ne pas utiliser ces méthodes de calcul par souci de simplicité.

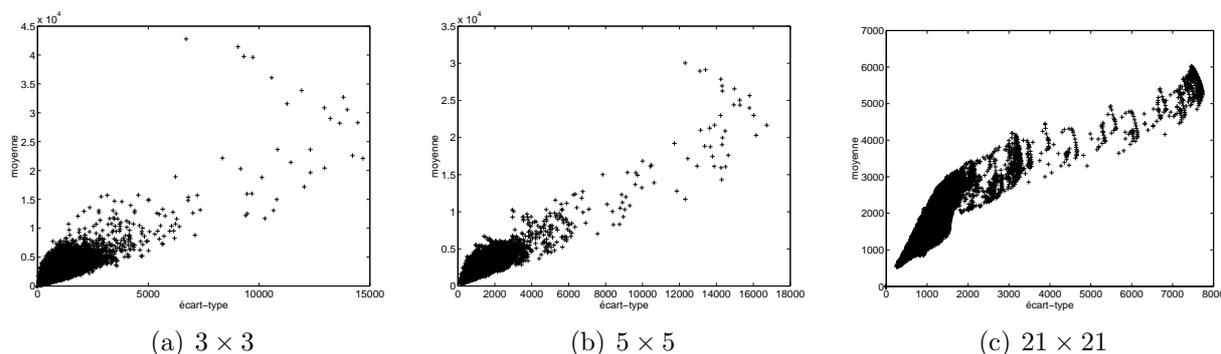


FIG. 3.5 – Représentation moyenne / écart-type d’une partie de l’image A.

### 3.3.2 Interprétation de la représentation

Plusieurs observations peuvent être faites sur la représentation moyenne / écart-type d’une image sonar (figure 3.4). Ces observations découlent des propriétés statistiques décrites dans ce chapitre et dans le chapitre précédent.

#### 3.3.2.1 Relation de proportionnalité du fond bruité

Sur cette représentation moyenne / écart-type, nous pouvons tout d’abord remarquer une orientation générale linéaire du nuage de points.

Si nous superposons les relations de proportionnalité calculées selon divers modèles statistiques du fond bruité (voir le chapitre précédent) à la représentation (figure 3.6(a)), nous pouvons voir que les points suivent approximativement les droites ainsi construites. De plus, nous pouvons vérifier à nouveau que la loi de Weibull donne une meilleure estimation de la relation de proportionnalité (pente 1,57) que celle de Rayleigh (pente 1,91). Avec les lois K, nous obtenons approximativement la même pente qu’avec la loi de Weibull.

Dans un deuxième temps, nous effectuons une régression linéaire, en utilisant la méthode des moindres carrés, sur l’ensemble des points représentant les pixels dans le plan moyenne / écart-type et nous reportons la droite ainsi calculée sur la représentation (figure 3.6(a)). Nous pouvons ainsi remarquer que la régression linéaire permet une bonne approximation de la relation de proportionnalité entre la moyenne et l’écart-type et donne sensiblement les mêmes résultats que les modèles théoriques (à  $10^{-2}$  près environ). En effet, les pixels du fond bruité étant largement majoritaires sur l’image sonar, le calcul de la régression linéaire prend en compte essentiellement les représentants de ces pixels dans le plan moyenne / écart-type et approche ainsi assez bien la relation entre ces grandeurs.

#### 3.3.2.2 Modèle statistique local

Les propriétés statistiques locales décrites dans le paragraphe 3.2.2 se retrouvent également dans l’interprétation des représentations moyenne / écart-type. En effet, des structures en forme de “cornes” peuvent être observées sur la représentation. Si l’on superpose les arcs

d'ellipses calculés sur les deux échos principaux présents sur l'image sonar, à partir de l'équation 3.12, nous pouvons alors voir qu'ils sont une assez bonne représentation de la répartition des points les plus éloignés de l'origine du repère.

Nous allons voir dans le paragraphe suivant que chacune de ces structures peut être associée à un écho de l'image sonar.

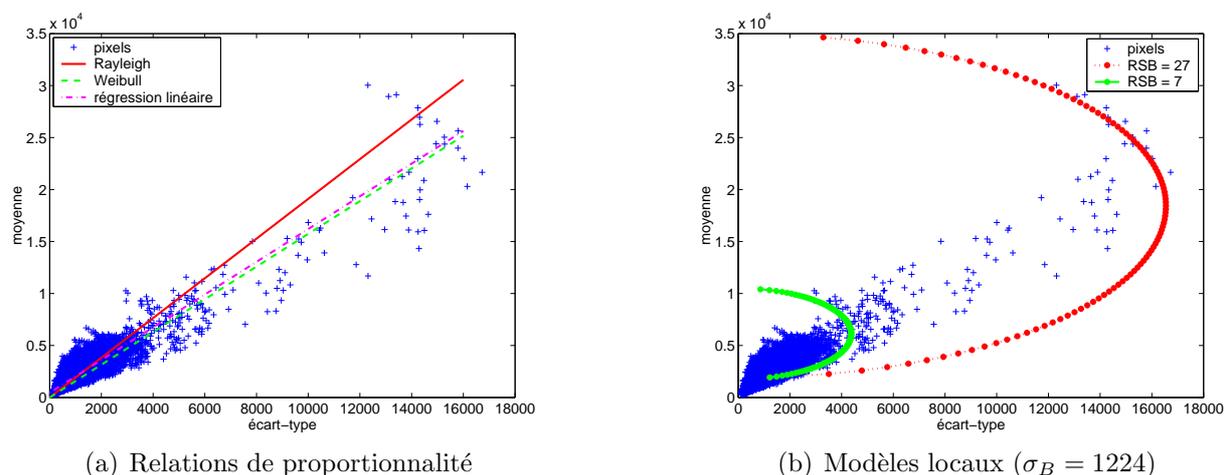


FIG. 3.6 – Interprétation d'une représentation moyenne / écart-type.

### 3.3.3 Liens avec l'image sonar

Afin de mettre en évidence les propriétés intéressantes de la représentation moyenne / écart-type, nous la comparons à l'image sonar d'origine (figure 3.7).

Après un étiquetage manuel, nous pouvons voir que le nuage de points proche de l'origine du repère correspond à la réverbération du fond marin, avec des moyennes et des écart-types faibles. Nous pouvons également remarquer que les arcs d'ellipses sont associés aux échos de l'image sonar. Deux de ces structures principalement sont visibles sur la représentation, chacune correspondant à un écho spécifique sur l'image d'origine. Les extrémités de ces structures, avec des moyennes élevées et des écart-types relativement faibles, sont associées aux centres des échos, ces derniers étant des éléments déterministes. Les points intermédiaires, avec des écart-types élevés et des moyennes croissantes, correspondent à la transition entre les échos et le fond bruité.

Ces différentes propriétés peuvent alors être utilisées pour une classification des différents éléments de l'image sonar, en observant sa représentation moyenne / écart-types et les différentes structures présentes sur celle-ci.

Il semble alors possible d'isoler chacun des échos de l'image sonar d'origine à partir des arcs d'ellipses de la représentation moyenne / écart-type. Une idée serait alors de "suivre" ces structures à partir d'un point (le germe) afin de segmenter l'écho associé. Une méthode similaire a ainsi été proposée par Hory [Hor02] dans la segmentation de spectrogrammes.

Mais une telle méthode paraît *a priori* assez complexe, d’autant plus que les échos que l’on cherche à isoler sont de petite taille, sont assez bien séparés les uns des autres et peuvent être assez nombreux (le nombre de germes pourrait alors être très élevé). Il serait alors plus aisé de les segmenter “tous à la fois” quitte à les séparer ensuite en recherchant les composantes connexes. C’est ce que nous proposons par la suite.

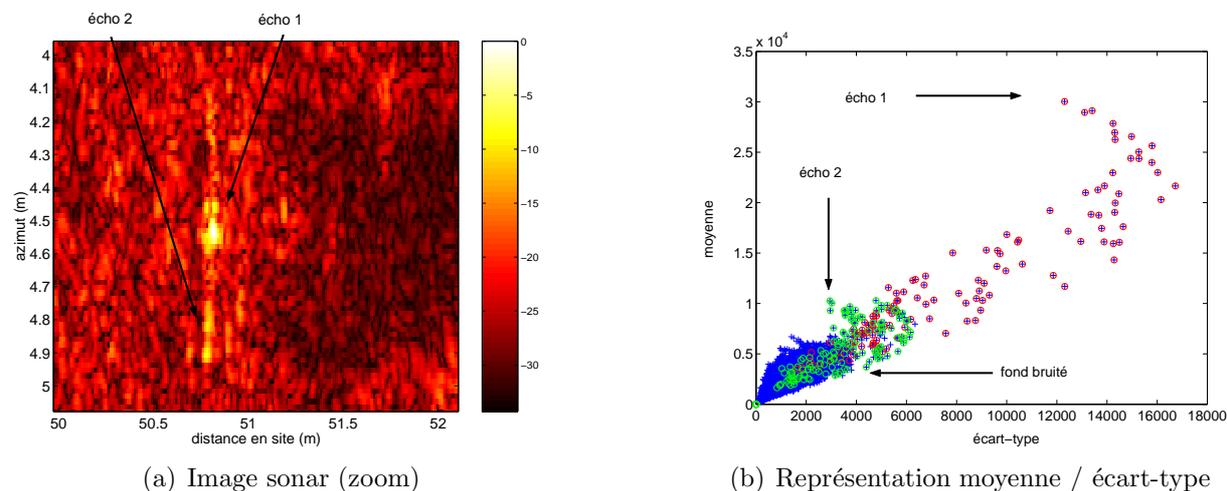


FIG. 3.7 – Comparaison entre l’image sonar et sa représentation moyenne / écart-type.

## 3.4 Segmentation automatique des images sonar

### 3.4.1 Principe de la méthode de segmentation

Afin de mettre en évidence les caractéristiques des échos et de localiser des régions d’intérêt pour la détection et la classification des objets présents, une segmentation des images sonar peut être réalisée afin de séparer les pixels associés aux échos de ceux du fond bruité. Ceci peut se faire en appliquant un simple seuillage dans le repère moyenne / écart-type.

Le principe de la méthode de segmentation proposée provient de l’observation faite précédemment selon laquelle la représentation des pixels du fond bruité dans le plan moyenne / écart-type est proche de l’origine du repère. Il semble alors relativement aisé d’isoler ces pixels en sélectionnant les points correspondants sur la représentation moyenne / écart-type. L’idée est alors d’utiliser des seuils en écart-type et en moyenne, et de mettre les pixels correspondant aux points en dessous de ces seuils sur la représentation à zéro sur l’image, et les autres à 1. Nous obtenons ainsi une image binaire correspondant à une segmentation des échos de l’image sonar d’origine (figure 3.8).

La relation de proportionnalité entre la moyenne et l’écart-type du fond bruité permet d’évaluer le seuil en moyenne une fois le seuil en écart-type fixé. Afin d’estimer ce coefficient

de proportionnalité et en déduire la valeur du seuil en fonction d'un autre, deux solutions principales existent :

- Nous prenons le coefficient calculé selon un modèle statistique du bruit (chapitre 2). D'après les différentes observations faites précédemment, la loi de Weibull semble être le meilleur compromis entre l'efficacité de modélisation et la complexité de l'estimation des paramètres.
- Nous prenons le coefficient calculé par régression linéaire (paragraphe 3.3.2.1).

Dans ce mémoire, nous avons choisi la première solution, les estimations des paramètres de la loi de Weibull ayant été préalablement effectuées (figure 3.8(a)). Mais, le choix de la deuxième solution ne change pratiquement pas les résultats et peut être très intéressant si l'on ne veut pas estimer le modèle statistique du fond bruité.

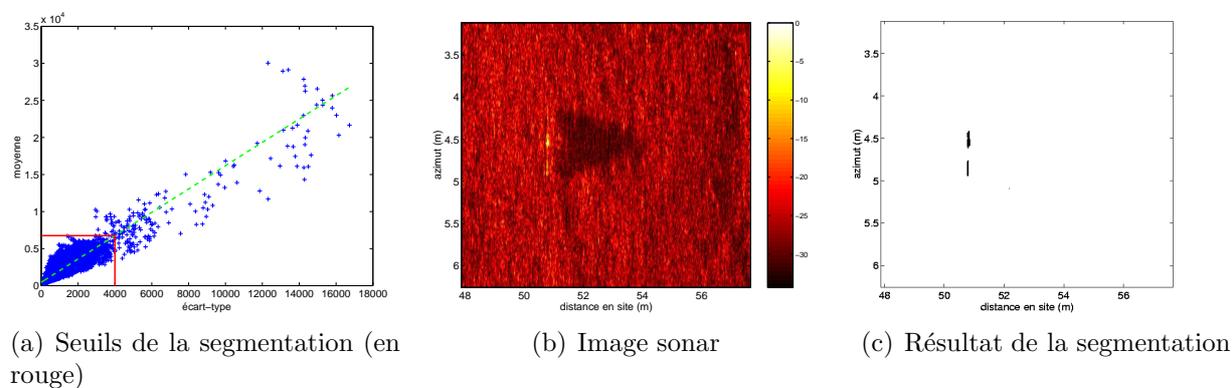


FIG. 3.8 – Segmentation d'une image sonar (seuils : écart-type = 4000 ; moyenne = 6751).

## 3.4.2 Automatisation de la segmentation

### 3.4.2.1 Principe de l'automatisation

Dans le paragraphe précédent, nous avons proposé une méthode de segmentation avec un seuil en écart-type fixé par l'opérateur, le seuil en moyenne s'en déduisant par les relations de proportionnalité (équations 2.7, 2.11, 2.25 et 2.29). Dans ce paragraphe, nous proposons d'automatiser le réglage de ce seuil afin d'avoir une "segmentation automatique" de l'image sonar.

Pour cela, nous effectuons une segmentation progressive de l'image sonar en diminuant progressivement le seuil en écart-type (figure 3.9). Nous voyons ainsi les régions segmentées s'élargir et de nouvelles régions apparaître, jusqu'à ce qu'on segmente des régions du fond bruité.

Notre but sera alors, afin de rendre automatique ce processus de segmentation, de se donner un critère d'arrêt de cette segmentation progressive afin de fixer un seuil "idéal" au dessous duquel on commencerait à segmenter des régions du fond.

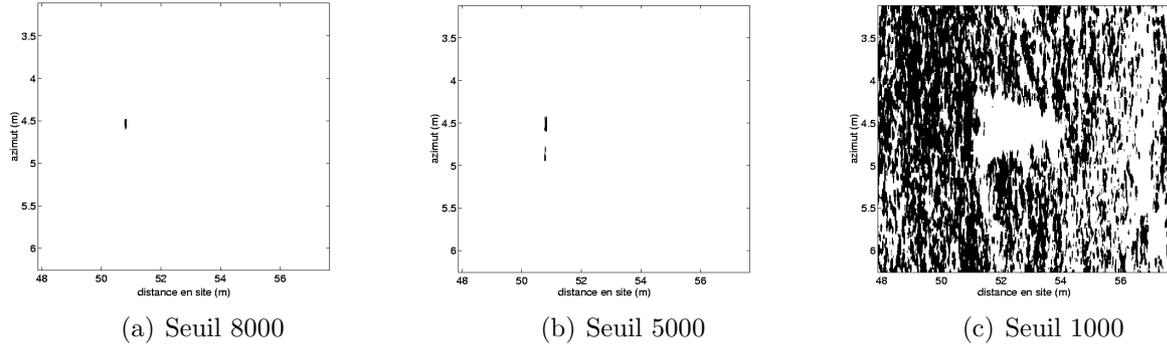


FIG. 3.9 – Résultats de la segmentation pour différents seuils en écart-type.

### 3.4.2.2 Choix du critère d’arrêt

Afin d’évaluer automatiquement ce seuil, des critères tels que la distance de Kolmogorov (voir le chapitre 2) peuvent être utilisés. On évalue ainsi pour chaque seuil la correspondance de la région non segmentée (pixels de valeur nulle) à celle d’un fond bruité selon un modèle statistique préalablement estimé [Hor02]. Ainsi, nous estimerions que l’image est bien segmentée quand le critère devient inférieur à une valeur préalablement fixée. Mais, ceci nécessite une modélisation statistique très précise du fond bruité.

L’utilisation d’un critère d’entropie peut être une autre solution. Un tel critère a déjà été utilisé dans la segmentation d’images, le plus souvent en utilisant l’histogramme de celles-ci [Pun80, Pun81, LLF04]. En effet, l’entropie permet généralement d’évaluer la dispersion de valeurs, ou d’autres éléments. Or, dans notre cas, lorsqu’on atteint un certain seuil en écart-type, on commence à segmenter des régions du fond bruité. En supposant que le fond est régulier et ne comporte pas de structure particulière, ces régions sont “éparpillées” dans l’image segmentée.

Pour notre segmentation, nous choisissons alors de définir un critère d’entropie évalué en comptant le nombre de pixels segmentés colonne par colonne (respectivement ligne par ligne) sur l’axe des abscisses (respectivement des ordonnées) (figure 3.10). Une fois les résultats normalisés, afin de pouvoir les considérer comme des densités de probabilité, nous calculons l’entropie  $H_{\text{axe}}$  sur chaque axe selon la formule classique de l’entropie de Shannon :

$$H_{\text{axe}} = - \sum_{i \in \mathcal{I}} p_{\text{axe}}(i) \log_2 p_{\text{axe}}(i) \quad (3.19)$$

avec  $p_{\text{axe}}(i)$  le “nombre de pixels segmentés” (après normalisation) dans la colonne (respectivement la ligne)  $i$ ,  $\mathcal{I} = \{i = 1 \dots N_{\text{axe}} \text{ tels que } p_{\text{axe}}(i) \neq 0\}$ , et  $N_{\text{axe}}$  le nombre de colonnes (respectivement de lignes). Ces critères nous donnent une estimation de la dispersion des pixels segmentés selon les deux axes : plus l’entropie est élevée, plus les pixels segmentés sont uniformément dispersés sur l’image. Le seuil atteint alors le niveau du fond bruité.

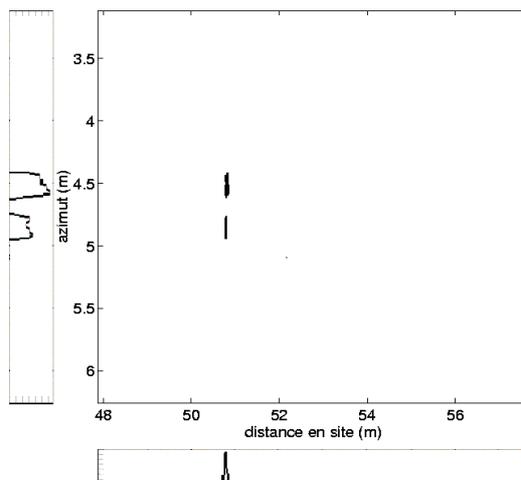


FIG. 3.10 – Image sonar segmentée et répartition des pixels segmentés selon les deux axes.  
Entropies calculées : axe des X  $\approx 3,46$  ; axe des Y  $\approx 4,58$

En effectuant une segmentation progressive (le seuil en écart-type est diminué progressivement), nous pouvons observer une augmentation de l’entropie selon les deux axes, mais cette croissance n’est pas régulière (figure 3.11). Nous pouvons voir deux ruptures de pente, dont une est plus forte, sur l’axe des azimuts, et une rupture forte sur l’axe en site. Ces ruptures de pente sont indiquées par des flèches sur la figure 3.11 : la rupture 1, seulement visible en azimut, est à un écart-type d’environ 6250, et la rupture 2 à environ 4000.

Pour comprendre la cause de ces irrégularités, la figure 3.9 présente les résultats des segmentations à différentes valeurs de seuils en écart-type entre les ruptures de pente. Nous pouvons alors voir une segmentation d’un premier écho quand le seuil décroît. Ensuite, un deuxième écho commence à être segmenté, ce qui explique l’augmentation rapide de l’entropie (rupture 1), les pixels segmentés étant rassemblés en deux régions distinctes au lieu d’une seule. Enfin, le fond bruité commence à être segmenté à son tour, ce qui explique la brusque augmentation de l’entropie (rupture 2). Les deux échos segmentés étant parallèles à l’axe des azimuts, la première rupture de pente n’est visible que sur l’axe des azimuts : en effet, tout au long de la segmentation progressive, avant que le fond commence à être segmenté, l’axe en site ne “voit” seulement qu’une région segmentée.

En conséquence, la segmentation optimale, permettant de voir les échos avec une taille maximale, mais avec le moins d’éléments du fond possible, est obtenue avec un seuil correspondant à la rupture de pente la plus élevée dans le graphe de l’entropie. Une segmentation utilisant un seuil plus faible commence à segmenter des éléments du fond.

### 3.4.2.3 Choix du seuil de la segmentation

Le seuil “idéal”, donnant le résultat de la segmentation automatique, peut être automatiquement calculé sur les profils d’entropies présentés ci-dessus. Pour cela, on combine tout d’abord les deux profils calculés selon chaque axe en utilisant un opérateur : maxi-

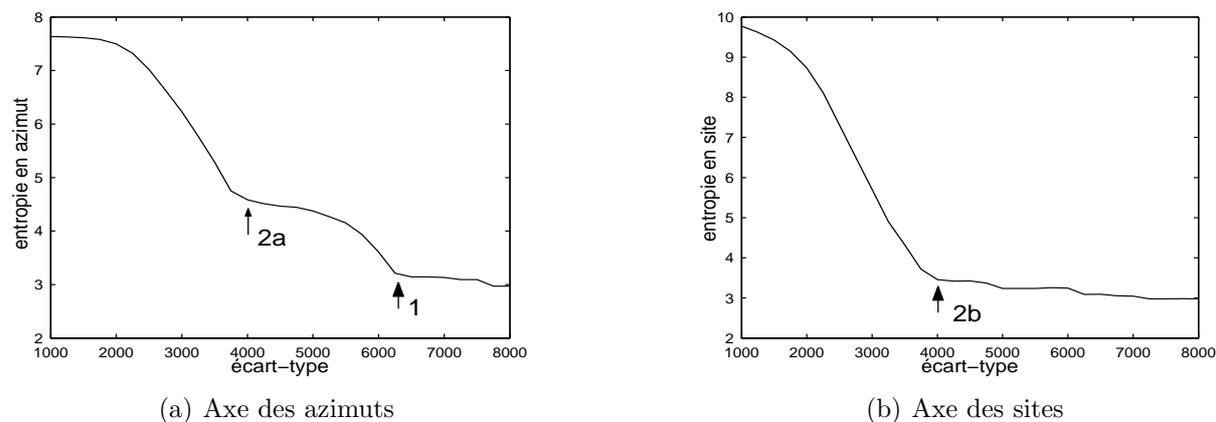


FIG. 3.11 – Variation des entropies selon les deux axes en fonction du seuil en écart-type.

num, somme simple, somme quadratique, . . . Nous avons choisi ici d'utiliser le maximum des entropies selon chaque axe pour chaque seuil (figure 3.12(a)), cet opérateur permettant de bien mettre en évidence l'apparition d'une nouvelle région segmentée indépendamment de sa position dans l'image. Mais, les autres combinaisons ont été testées avec des résultats très similaires.

L'objectif est alors de fixer le seuil de la segmentation. D'après les remarques faites dans le paragraphe précédent, celui-ci doit se trouver "au pied" d'une grande rupture de pente dans le profil de l'entropie. Pour cela, nous utilisons la dérivée du profil d'entropie (figure 3.12(b)). Le maximum de cette dérivée permet alors de localiser la rupture de pente la plus forte sur le profil d'entropie. Afin de localiser le pied de cette rupture, nous prenons alors le seuil, supérieur à la position de ce maximum, correspondant à l'endroit où la dérivée passe en dessous de la moitié de la valeur de ce maximum. Par exemple, sur la figure 3.12(b), le maximum étant à une valeur d'environ  $3,0 \cdot 10^{-3}$  à l'écart-type 2600, nous sélectionnons comme seuil "idéal" 4000, celui-ci correspondant à l'écart-type immédiatement suivant avec une dérivée inférieure à  $1,5 \cdot 10^{-3}$ . En effet, juste avant une rupture de pente, la pente du profil est assez faible et croit rapidement au niveau de la rupture. La recherche de ce seuil permet alors de repérer assez efficacement le "pied" de la rupture de pente la plus forte correspondant au passage de la segmentation des objets recherchés à celle du fond bruité.

Le résultat sur l'image 3.8(b) est présenté sur la figure 3.8(c) (seuil en écart-type de 4000) où nous pouvons voir les deux échos caractérisant la mine.

Nous obtenons ainsi une méthode de segmentation des images sonar entièrement automatisée.

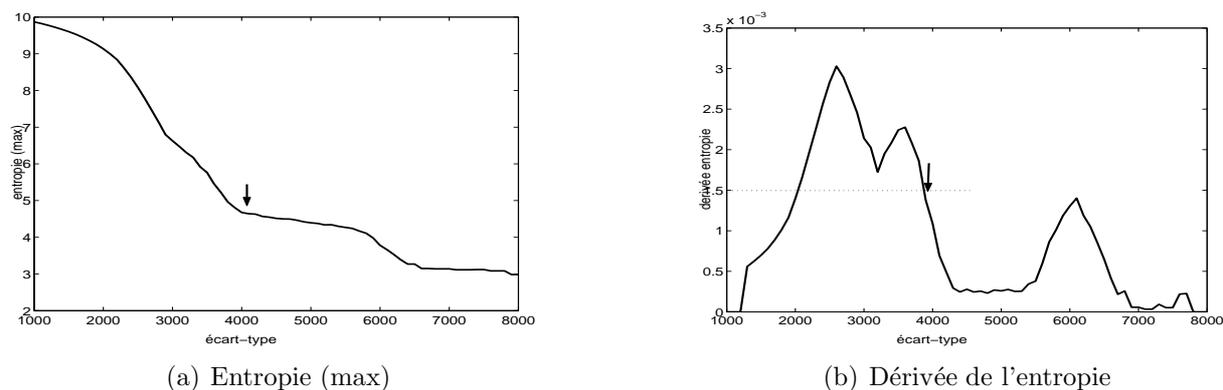


FIG. 3.12 – Choix du seuil à partir du critère d'entropie et de sa dérivée (seuil choisi : voir le flèche).

## 3.5 Application aux données SAS

Afin de mettre en évidence l'intérêt de la méthode de segmentation proposée, celle-ci est testée sur plusieurs images issues de données SAS aux propriétés différentes. Les résultats sont comparés à ceux obtenus avec une méthode de détection consistant à seuiller directement les données initiales.

### 3.5.1 Evaluation des performances

Pour une mesure quantitative des performances, nous calculons des courbes COR (Caractéristique Opérationnelle de Réception), représentant l'évolution de la probabilité de détection en fonction du taux de fausse alarme quand la valeur du seuil en écart-type augmente. Ces probabilités sont évaluées en utilisant une image contenant des masques correspondant aux régions de l'image sonar susceptibles d'être des échos. Cette image est construite manuellement par un expert.

On note  $A$  l'ensemble des pixels appartenant aux échos et  $B$  l'ensemble des pixels segmentés pour un seuil donné (figure 3.13). Si la taille (en pixels) de l'ensemble  $X$  est donnée par  $N_X$ , la probabilité de détection  $p_d$  est définie par :

$$p_d = \frac{N_{A \cap B}}{N_A} \quad (3.20)$$

Le taux de fausse alarme  $p_{fa}$  se calcule selon :

$$p_{fa} = \frac{N_{\bar{A} \cap B}}{N_{\bar{A}}} \quad (3.21)$$

$A \cap B$  étant l'intersection des régions  $A$  et  $B$  et  $\bar{A}$  l'ensemble complémentaire de  $A$ . On a donc  $N_{\bar{A}} = N - N_A$ ,  $N$  étant la taille de l'image. On peut remarquer que ces grandeurs varient entre 0 et 1.

Notons que ces définitions peuvent paraître inhabituelles à la communauté de la chasse aux mines. En effet, les probabilités de détection et de fausse alarme sont définies ici au niveau pixel et non au niveau cible. En effet, étant donné le faible nombre d'objets recherchés sur nos images, des définitions plus usuelles ne seraient pas très informatives. De plus, si nous considérons la détection d'un écho par seulement un pixel, elle s'avérerait insuffisante pour un expert qui serait incapable de le distinguer d'une fausse alarme. Les définitions proposées nous permettront alors d'évaluer la qualité de détection de chaque écho (la taille de chaque région segmentée est ainsi prise en compte).

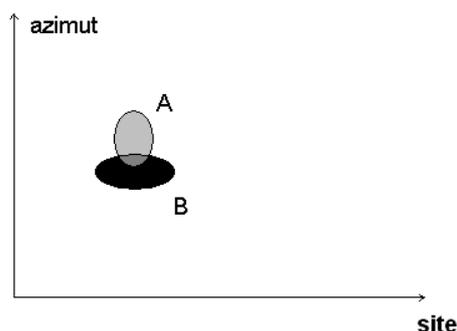


FIG. 3.13 – Evaluation de la probabilité de détection et du taux de fausse alarme.  $A$  est la région considérée par l'expert comme un écho,  $B$  est la région segmentée par la méthode proposée pour un seuil donné.

### 3.5.2 Segmentation des images SAS

Nous testons la méthode de segmentation proposée sur les données SAS présentées dans le chapitre 1, aux propriétés et aux contenus différents.

Les résultats de ces comparaisons sur les quatre images sont présentés sur les figures 3.14, 3.16, 3.18 et 3.20. Nous pouvons ainsi constater la performance de la méthode de segmentation proposée par rapport à un simple seuillage, la probabilité de détection étant toujours plus élevée pour un taux de fausse alarme donné. Il faut noter, cependant, que la probabilité de détection n'atteint pas immédiatement la valeur 1. Ceci est dû au fait que les régions sélectionnées comme "échos" par l'expert sont assez larges et grossières (formes rectangulaires). Ainsi, pour que la probabilité de détection soit proche de 1, les seuils (en écart-type pour la segmentation, en niveau de gris pour le seuillage) doivent être suffisamment bas, ce qui crée des fausses alarmes. De cette façon, le résultat "idéal", permettant d'avoir la probabilité de détection la plus élevée tout en limitant au maximum le taux de fausse alarme, n'atteint pas une probabilité de détection égale à 1. Ceci est surtout vrai pour l'image E (figure 3.18), où les échos sont composés de points lumineux assez dispersés, alors que les régions "échos" de l'image de référence sont très homogènes.

Afin d'illustrer ces remarques, et pour mettre en lumière l'intérêt de la segmentation automatique écrite dans ce chapitre, cette dernière est appliquée sur les quatre images

sonar. Les résultats sont alors comparés à un simple seuillage permettant d'atteindre un taux de fausse alarme relativement proche (figures 3.15, 3.17, 3.19 et 3.21).

Le seuil en écart-type est fixé pour la segmentation automatique en utilisant la variation de l'entropie en fonction de ce seuil et de sa dérivée (voir les petite flèches verticales visibles sur les graphes des entropies), selon la description faite dans le paragraphe 3.4.2.2. Nous voyons qu'ainsi on arrive à assez bien segmenter les principaux échos des images sonar en limitant au maximum les fausses alarmes (régions du fond segmentées). Ceci est confirmé sur les courbes COR (figures 3.14, 3.16, 3.18 et 3.20) où une flèche horizontale indique la position du résultat de la segmentation sur la courbe. Nous pouvons ainsi remarquer que cette segmentation permet d'atteindre une probabilité de détection élevée pour un taux de fausse alarme faible (position près du "coude" de la courbe associée à la segmentation).

L'intérêt du résultat obtenu est mis en évidence par les seuillages simples permettant d'avoir un taux de fausse alarme équivalent. En effet, nous pouvons voir que, pour un taux de fausse alarme donné, les régions sélectionnées par le seuillage, correspondant aux échos, sont généralement de tailles plus faibles et sont moins "homogènes" que leurs équivalentes pour la segmentation (voir en particulier l'écho de la mine cylindrique sur les figures 3.21(c) et 3.21(d)). De plus, certaines régions du fond apparaissent avec le seuillage, de tailles assez faibles, mais comparables à celles des échos, ce qui fait augmenter considérablement le nombre de composantes connexes sur les résultats des seuillages.



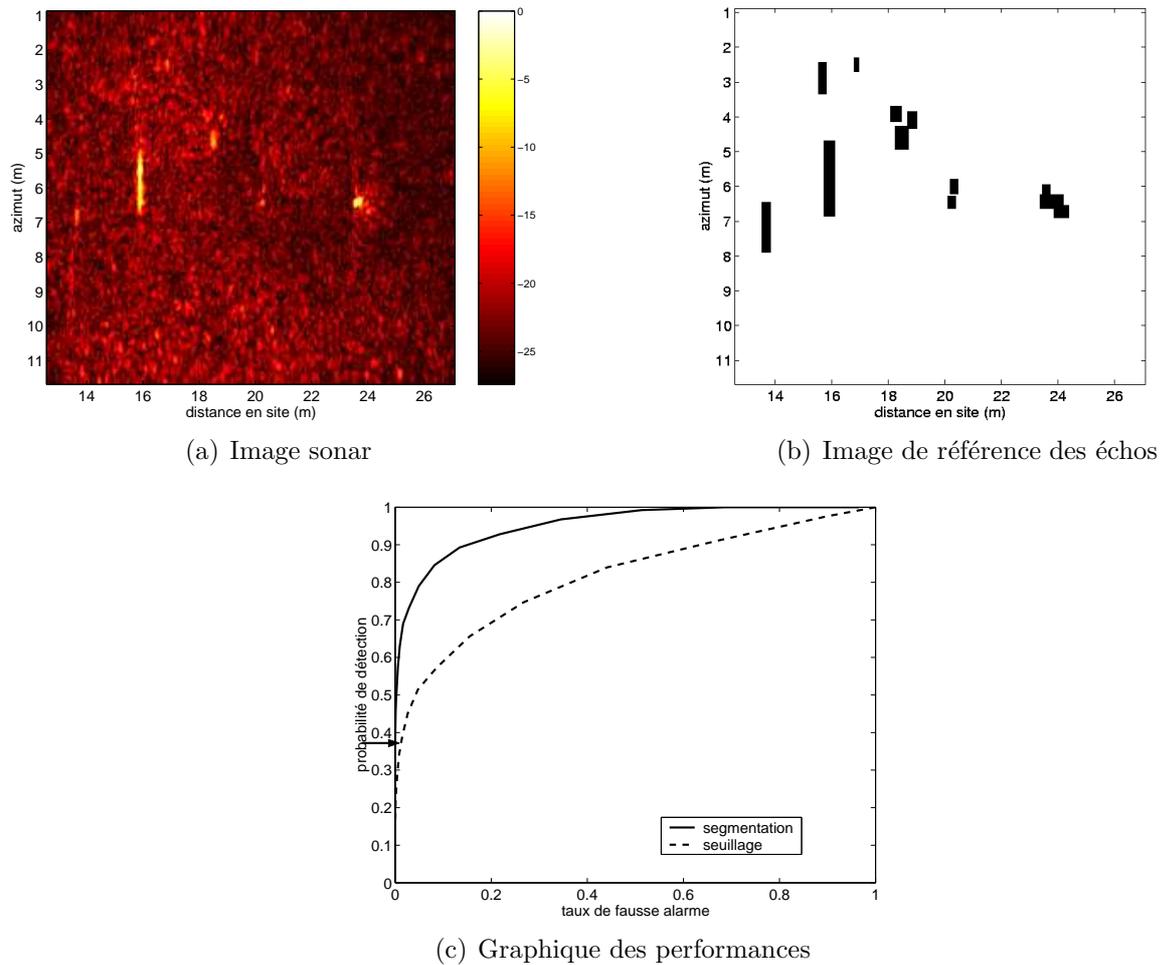
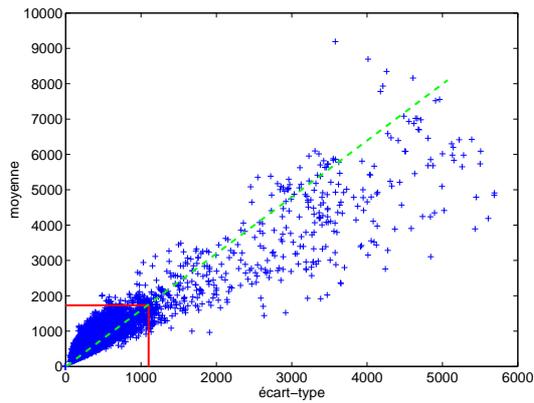
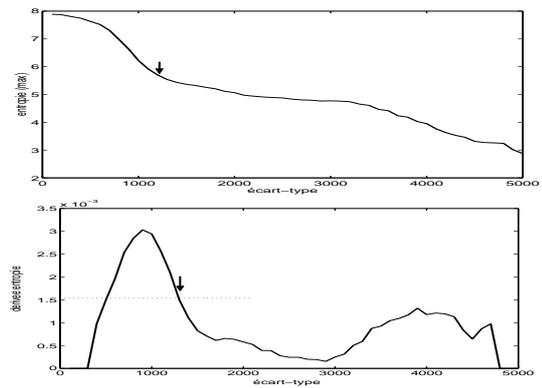


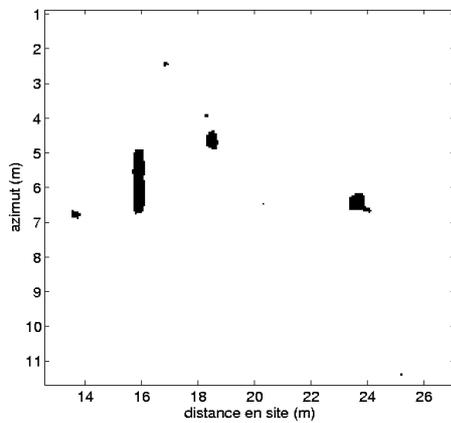
FIG. 3.14 – Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image C (chapitre 1).



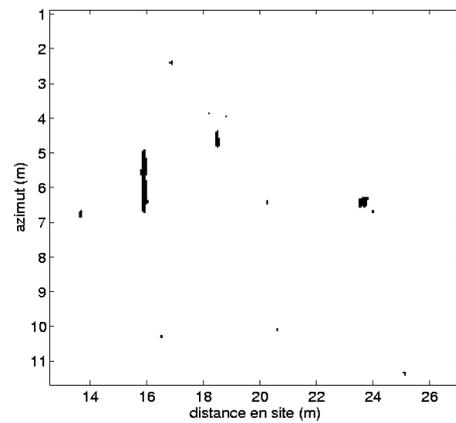
(a) Représentation moyenne / écart-type : droite de Weibull en vert, seuils de la segmentation automatique en rouge



(b) Variation de l'entropie (haut) et sa dérivée (bas)



(c) Résultat de la segmentation automatique : écart-type = 1200, moy. = 1888,  $p_{fa} = 1,10 \cdot 10^{-4}$  et  $p_d = 0,381$ ; 8 composantes connexes



(d) Résultat d'un simple seuillage : seuil = 3200,  $p_{fa} = 1,28 \cdot 10^{-4}$  et  $p_d = 0,160$ ; 12 composantes connexes

FIG. 3.15 – Résultats de la segmentation automatique et d'un simple seuillage sur l'image C.

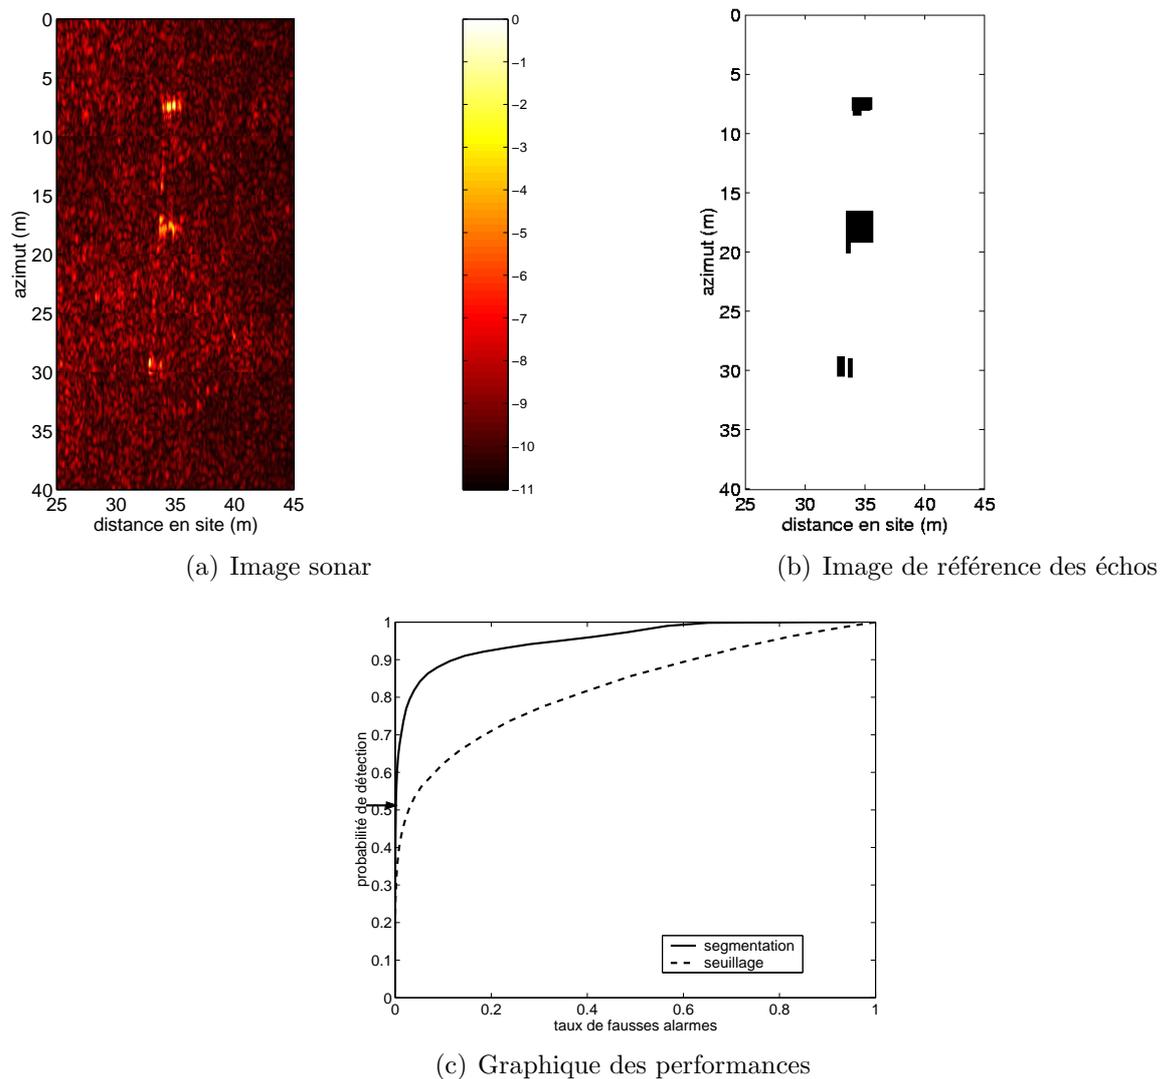
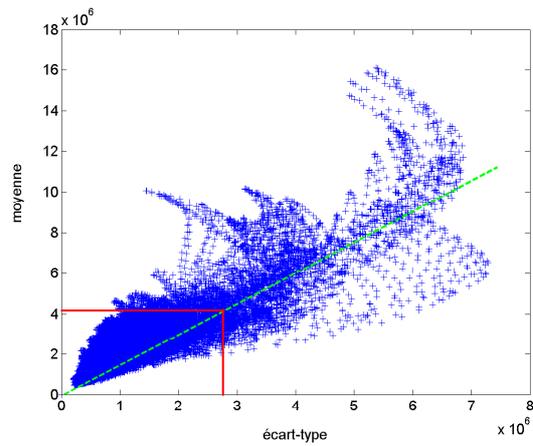
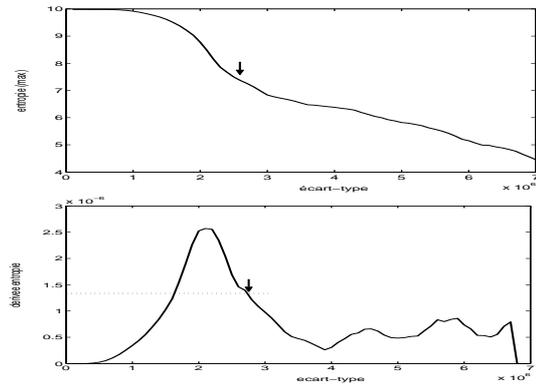


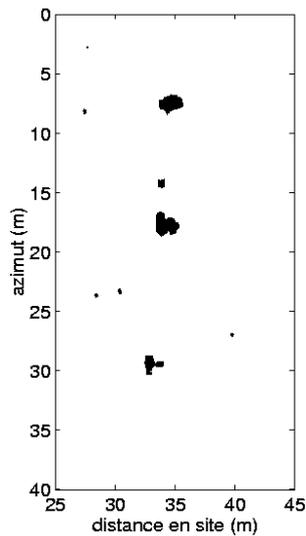
FIG. 3.16 – Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image D (chapitre 1).



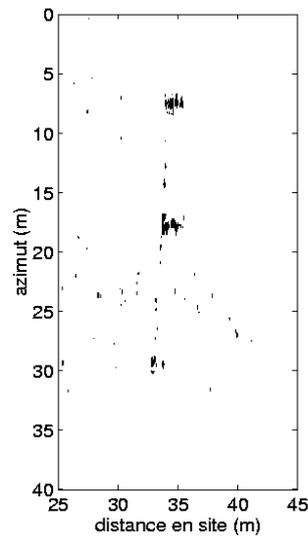
(a) Représentation moyenne / écart-type : droite de Weibull en vert, seuils de la segmentation automatique en rouge



(b) Variation de l'entropie (haut) et sa dérivée (bas)



(c) Résultat de la segmentation automatique : écart-type =  $2,7 \cdot 10^6$ , moy. =  $4,41 \cdot 10^6$ ,  $p_{fa} = 1,90 \cdot 10^{-2}$  et  $p_d = 0,530$ ; 9 composantes connexes



(d) Résultat d'un simple seuillage : seuil =  $6,3 \cdot 10^6$ ,  $p_{fa} = 1,80 \cdot 10^{-3}$  et  $p_d = 0,295$ ; 86 composantes connexes

FIG. 3.17 – Résultats de la segmentation automatique et d'un simple seuillage sur l'image D.

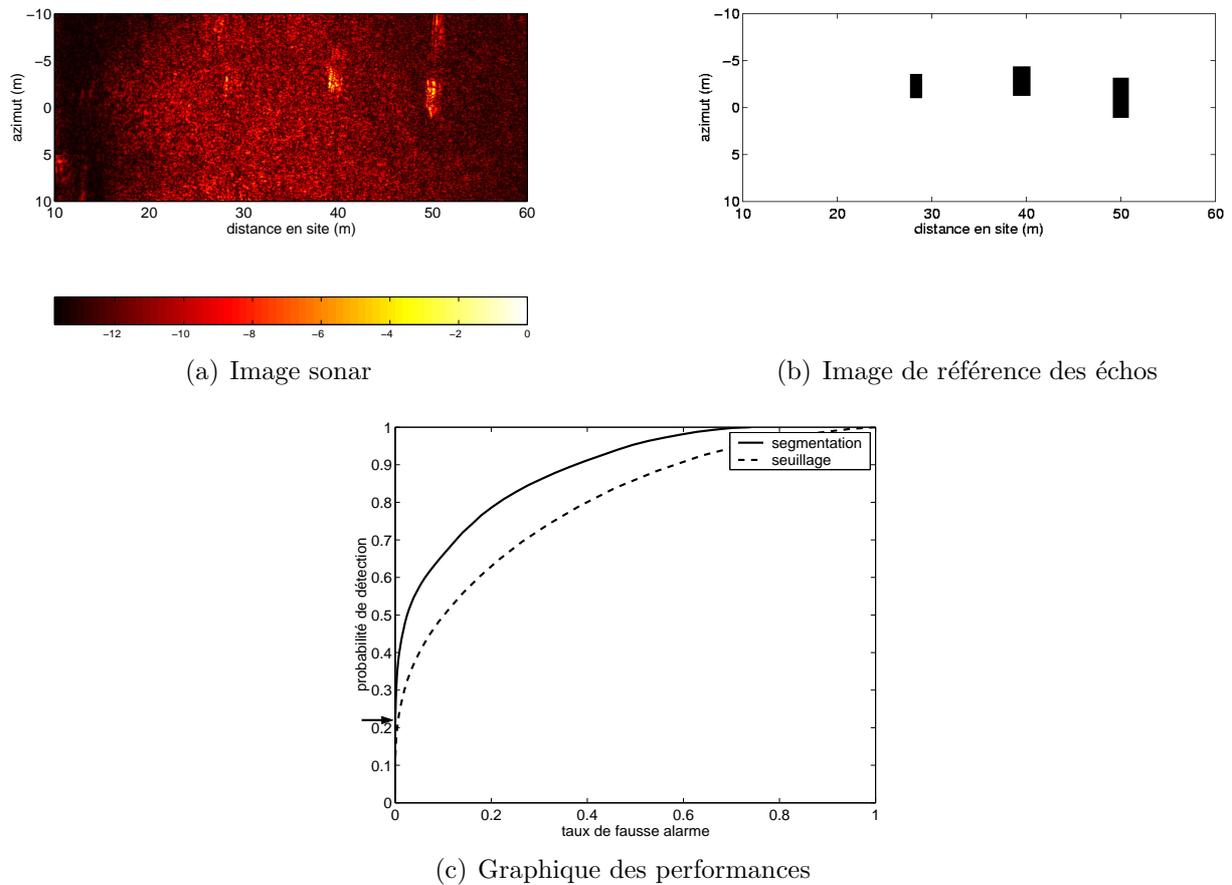
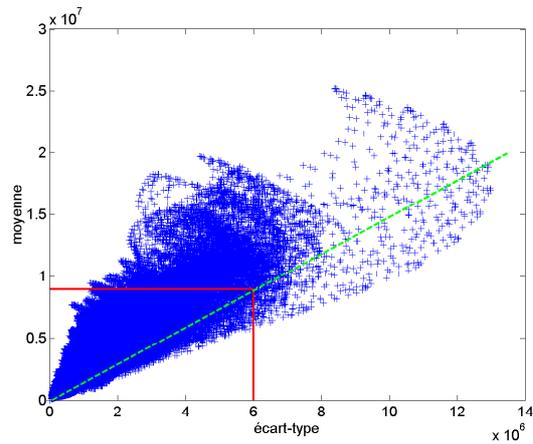
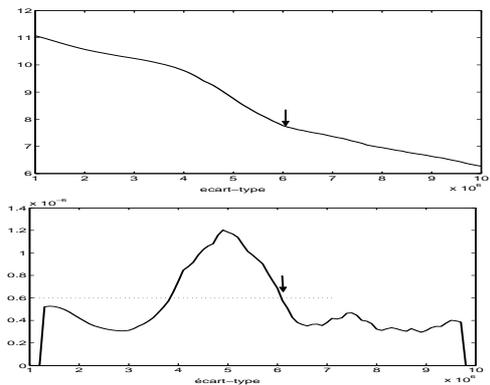


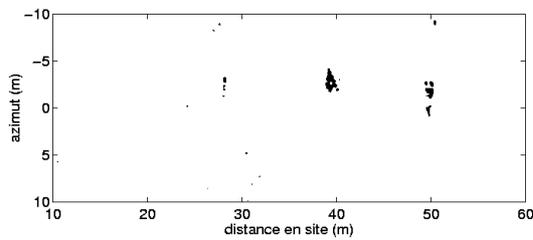
FIG. 3.18 – Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image E (chapitre 1).



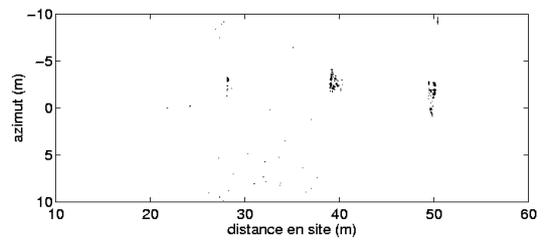
(a) Représentation moyenne / écart-type : droite de Weibull en vert, seuils de la segmentation automatique en rouge



(b) Variation de l'entropie (haut) et sa dérivée (bas)



(c) Résultat de la segmentation automatique : écart-type =  $6,0 \cdot 10^6$ , moy. =  $8,94 \cdot 10^6$ ,  $p_{fa} = 3,34 \cdot 10^{-4}$  et  $p_d = 0,216$ ; 27 composantes connexes



(d) Résultat d'un simple seuillage : seuil =  $1,27 \cdot 10^7$ ,  $p_{fa} = 3,32 \cdot 10^{-4}$  et  $p_d = 0,109$ ; 107 composantes connexes

FIG. 3.19 – Résultats de la segmentation automatique et d'un simple seuillage sur l'image E.

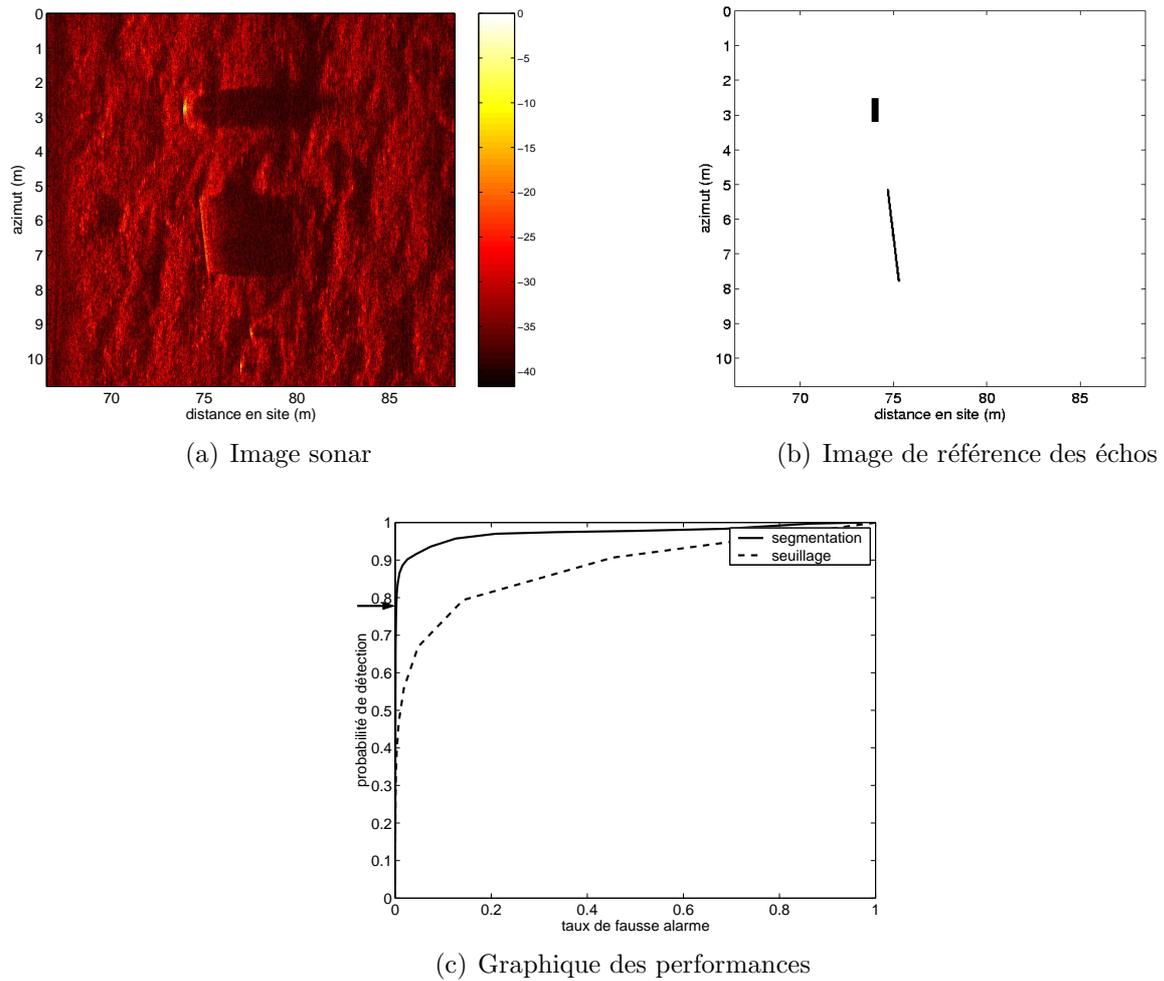
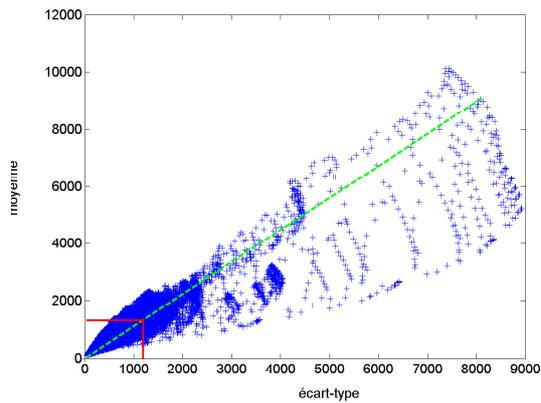
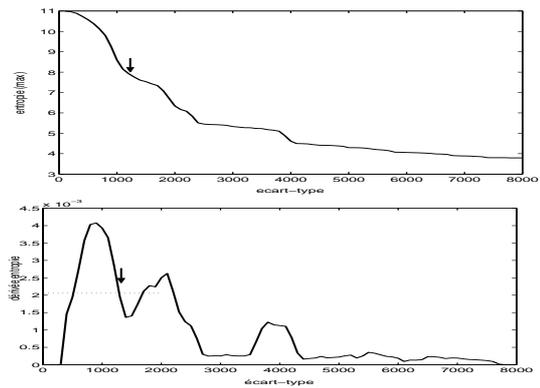


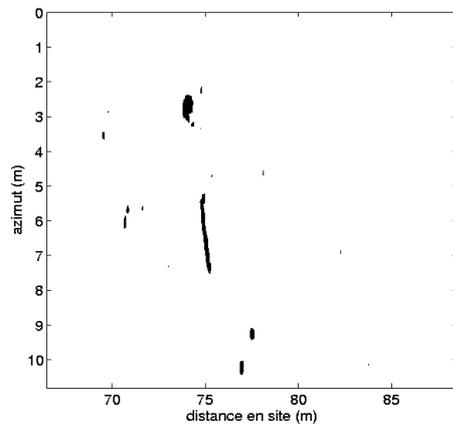
FIG. 3.20 – Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image B (chapitre 1).



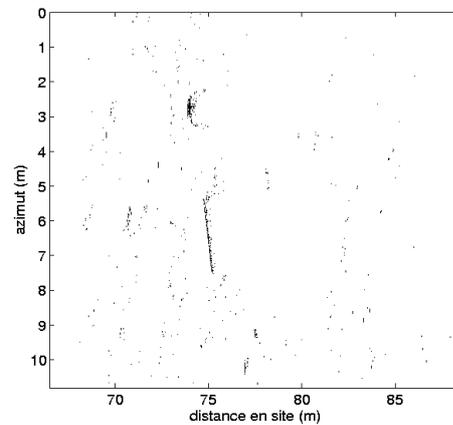
(a) Représentation moyenne / écart-type : droite de Weibull en vert, seuils de la segmentation automatique en rouge



(b) Variation de l'entropie (haut) et sa dérivée (bas)



(c) Résultat de la segmentation automatique : écart-type = 1200, moy. = 1363,  $p_{fa} = 2,70 \cdot 10^{-3}$  et  $p_d = 0,790$ , 21 composantes



(d) Résultat d'un simple seuillage : seuil = 2300,  $p_{fa} = 2,60 \cdot 10^{-3}$  et  $p_d = 0,377$ ; 773 composantes connexes

FIG. 3.21 – Résultats de la segmentation automatique et d'un simple seuillage sur l'image B.

## 3.6 Bilan

Nous avons donc proposé dans ce chapitre une méthode de détection des objets, sur les images sonar, à partir de leurs échos (figure 3.22). Cette méthode est basée sur les propriétés statistiques de ces images aux ordres 1 et 2 mises en évidence par la représentation moyenne / écart-type. L'automatisation utilise alors un critère d'arrêt, l'entropie, afin de fixer le seuil "idéal" pour avoir une segmentation des échos séparés des pixels du fond bruité. Celui-ci est fixé à partir de la dérivée du profil d'entropie obtenu en effectuant une segmentation progressive de l'image. Nous recherchons alors le seuil correspondant au "pied" de la rupture de pente la plus forte en prenant la valeur à laquelle la dérivée a diminué de moitié par rapport à son maximum.

Nous pouvons constater, de plus, que cette méthode n'utilise aucune connaissance *a priori*, si ce n'est une valeur très approchée de la taille des échos (pour le choix de la taille de la fenêtre de calcul pour calculer la représentation moyenne / écart-type), ce qui semble assez aisé, surtout si l'on connaît la résolution de l'image. Cette méthode permet alors une bonne segmentation de l'image y compris dans le cas d'un faible rapport signal à bruit (objets enfouis, voir les résultats obtenus sur les images C, D et E). L'apport de cette méthode par rapport à un simple seuillage est confirmé par les courbes COR calculées.

De plus, contrairement à d'autres méthodes proposées et que nous avons présentées dans le chapitre 1, celle-ci n'utilise pas la présence d'une ombre à proximité de l'écho segmenté. Les régions segmentées obtenues sont par ailleurs de taille suffisamment grandes pour pouvoir avoir une assez bonne description de l'objet et ne pas le confondre avec un artefact par son ou ses échos, mais suffisamment faibles pour avoir une bonne localisation des objets.

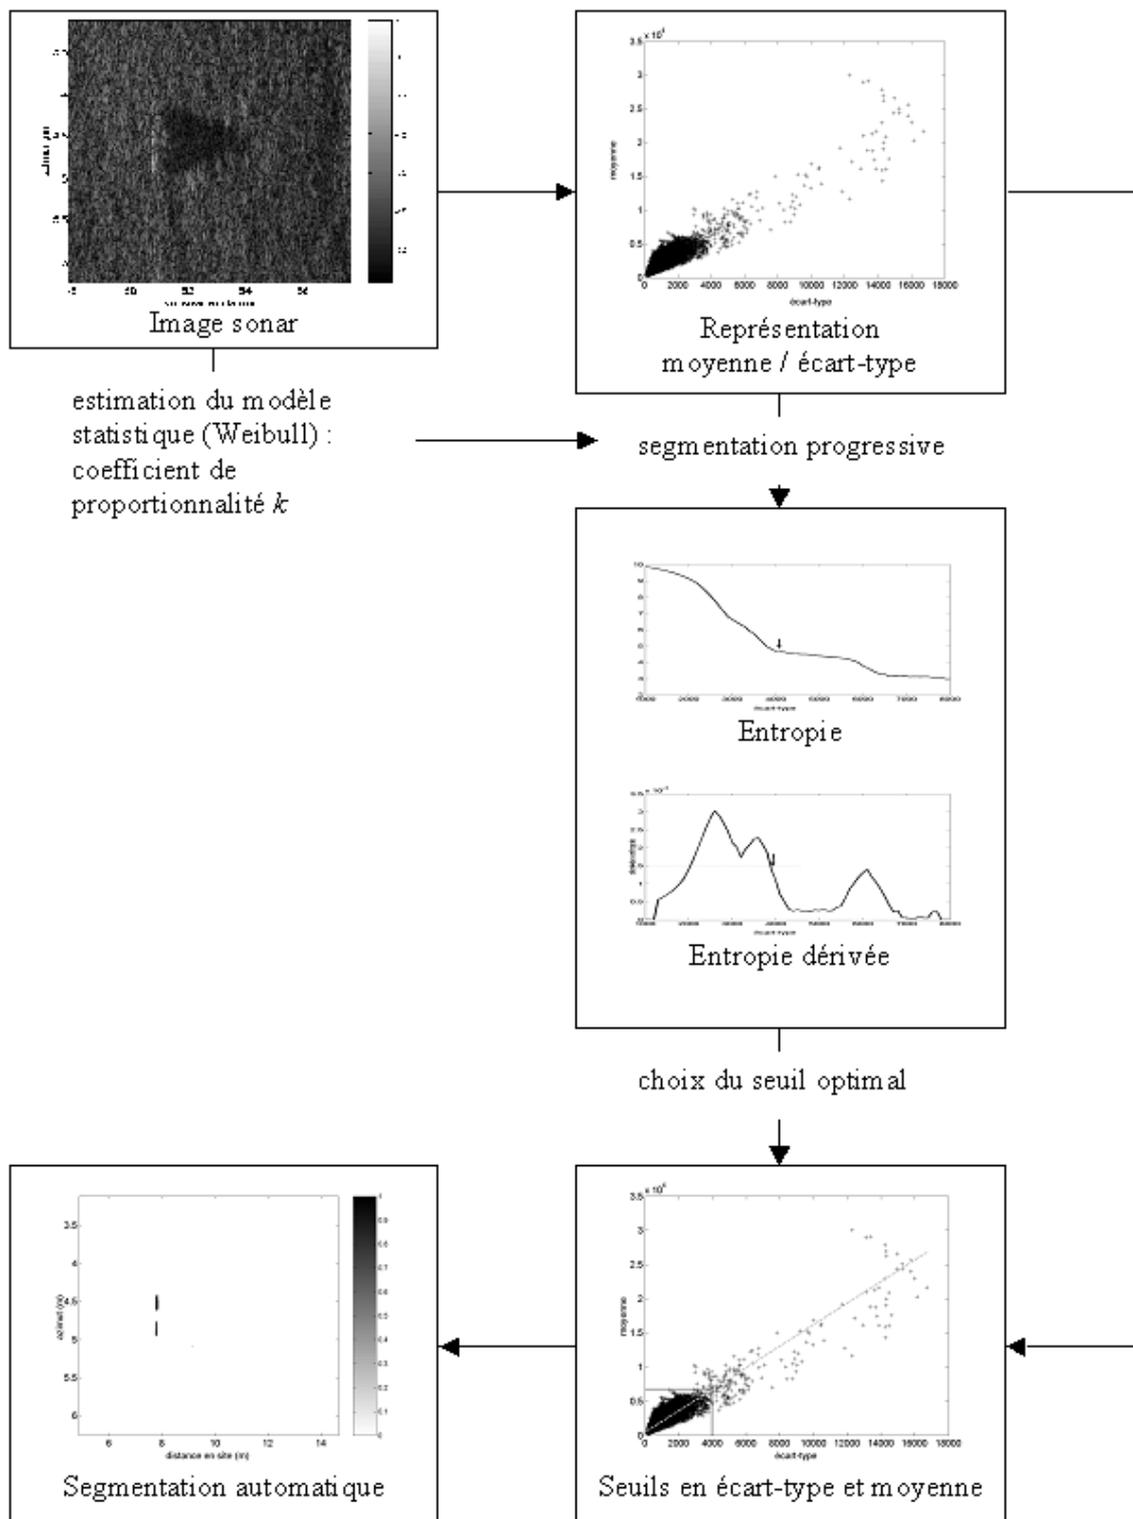


FIG. 3.22 – Schéma synthétique de la méthode de détection proposée : la segmentation automatique.



## Chapitre 4

# Utilisation des statistiques d'ordres supérieurs

Les Statistiques d'Ordres Supérieurs (SOS) sont un outil largement utilisé en traitement du signal, et plus rarement en traitement d'images.

Nous proposons dans ce mémoire une méthode de détection de régions déterministes, de petite taille, entourées par un fond bruité aléatoirement. L'utilisation de valeurs statistiques d'ordres 3 et 4, telles que le skewness et le kurtosis, évaluées localement sur l'image permettent de mettre en évidence la présence de ces régions. Les valeurs obtenues, ainsi que les paramètres (forme, taille, . . .) des structures ainsi constituées sur l'image résultante nous renseignent sur les propriétés des régions déterministes détectées.

Cette méthode fonctionne très efficacement dans le cas d'un fond bruité gaussien. L'application aux images sonar, dont le modèle statistique est plus complexe, s'effectue assez aisément et nous fournit une nouvelle méthode de détection des objets présents sur l'image basée sur les statistiques d'ordres 3 et 4.

---

**Sommaire**


---

<b>4.1</b>	<b>Introduction</b>	<b>83</b>
<b>4.2</b>	<b>Statistiques d'ordres supérieurs : définition et estimation</b>	<b>83</b>
4.2.1	Introduction aux SOS	83
4.2.2	Définitions et propriétés	84
4.2.2.1	Moments et cumulants	84
4.2.2.2	Skewness et kurtosis	85
4.2.3	Estimateurs	86
<b>4.3</b>	<b>Utilisation des statistiques d'ordres supérieurs pour la détection : cas gaussien</b>	<b>87</b>
4.3.1	Propriétés locales des SOS	87
4.3.1.1	Modélisation statistique	87
4.3.1.2	Evaluation locale des SOS	88
4.3.2	Application à la détection de petits objets : cas des RSB faibles	90
4.3.2.1	Approximations	91
4.3.2.2	Résultats obtenus	91
4.3.2.3	Evaluation numérique des résultats	93
4.3.3	Application à la détection de petits objets : cas des RSB élevés	94
4.3.3.1	Approximations	94
4.3.3.2	Résultats obtenus	95
4.3.4	Application à la détection de petits objets : cas des RSB intermédiaires	98
4.3.4.1	Skewness	98
4.3.4.2	Kurtosis	99
4.3.5	Détection avec un RSB élevé : focalisation et reconstruction de la région déterministe	100
4.3.5.1	Focalisation : approche par filtrage adapté	101
4.3.5.2	Prise en compte de l'incertitude sur la taille des régions d'intérêt	102
4.3.5.3	Reconstruction des régions d'intérêt	103
<b>4.4</b>	<b>Utilisation des statistiques d'ordres supérieurs pour la détection : application aux images sonar</b>	<b>105</b>
4.4.1	Spécificités des images sonar	106
4.4.1.1	Conséquences sur la détection	107
4.4.2	Résultats et évaluation	110
4.4.2.1	Résultats sur les données SAS	110
4.4.2.2	Evaluation quantitative des performances de détection	111
<b>4.5</b>	<b>Conclusion sur l'utilisation des statistiques d'ordres supérieurs</b>	<b>112</b>

---

## 4.1 Introduction

Dans le chapitre précédent, nous nous sommes intéressés à l'utilisation des statistiques d'ordres 1 et 2 pour la détection d'objets sur les images sonar. Les résultats obtenus nous ont montré tout l'intérêt qu'apportait l'évaluation de la moyenne et de l'écart-type localement sur l'image pour détecter les échos des objets présents.

Dans ce chapitre, nous allons alors nous intéresser aux statistiques d'ordres supérieurs (SOS), et en particulier aux valeurs statistiques d'ordres 3 et 4 (skewness et kurtosis). Nous allons donc tout d'abord nous pencher sur la définition et les propriétés de ces grandeurs statistiques, ainsi que les estimateurs de celles-ci. Nous allons dans un deuxième temps considérer l'utilisation de ces grandeurs, évaluées localement, pour la détection de régions déterministes de petite taille entourées d'un bruit gaussien. Nous verrons ensuite l'application de la méthode ainsi développée dans la détection d'objets en acoustique sous-marine et les adaptations dont on doit tenir compte lors de cette transposition à l'imagerie sonar. Cette méthode sera enfin testée et évaluée sur les images SAS présentées dans le chapitre 1.

## 4.2 Statistiques d'ordres supérieurs : définition et estimation

### 4.2.1 Introduction aux SOS

Les Statistiques d'Ordres Supérieurs (SOS) sont assez largement utilisées en traitement du signal et ont déjà été appliquées dans des domaines variés : astronomie (qui a fourni les toutes premières applications), traitement de données sismiques, communications et, plus récemment, géophysique, traitement de la parole, de signaux radar et sonar. Dans les quinze dernières années, plusieurs revues ont publié des numéros spéciaux sur ces techniques [Spe90, Spe94, Spe96]. Celles-ci permettent par exemple l'identification de systèmes linéaires par déconvolution aveugle, ou non-linéaires (filtre de Volterra). Elles ont également été utilisées en analyse de signaux non-stationnaires, en traitement d'antenne et en séparation de sources [LAC97].

Les SOS ont, par contre, été plus rarement utilisées en traitement d'images. Jacovitti [Jac91] a réalisé un état de l'art de leur utilisation en décomposition d'image, en déconvolution aveugle, en codage et en reconnaissance de formes. Des études ont également été effectuées en analyse de textures [CJD94, ACRKRA<sup>+</sup>05], et en segmentation par regroupement de données [RJD99]. Enfin, Carrato et Ramponi [CR93] ont proposé une méthode de détection des contours en utilisant le skewness (grandeur statistique d'ordre 3) appliqué à des images. Cet algorithme utilise le passage par zéro de cette grandeur (correspondant à une distribution symétrique) pour détecter les contours de façon performante et robuste [RC94].

## 4.2.2 Définitions et propriétés

### 4.2.2.1 Moments et cumulants

Soit  $X$  une variable aléatoire à valeurs réelles, de densité de probabilité  $p_X(x)$ . Les moments généralisés de  $X$  sont définis pour toute application réelle  $f$  par :

$$E[f(x)] = \int_{-\infty}^{+\infty} f(u)p_X(u)du \quad (4.1)$$

La première fonction caractéristique de  $X$  se définit alors en prenant  $f(x) = \exp(j\nu x)$ , où  $j$  désigne la racine carrée de  $-1$  :

$$\Phi_X(\nu) = E[e^{j\nu x}] = \int_{-\infty}^{+\infty} e^{j\nu u} p_X(u) du \quad (4.2)$$

Nous constatons donc que  $\Phi_X(\nu)$  est la transformée de Fourier de la densité de probabilité  $p_X(x)$  de  $X$ .

Cette fonction caractéristique est continue en tout point et vaut 1 à l'origine. Elle est donc non nulle dans un voisinage de l'origine, sur lequel on pourra définir la seconde fonction caractéristique [LAC97] :

$$\Psi_X(\nu) = \log(\Phi_X(\nu)) \quad (4.3)$$

où  $\log$  désigne le logarithme népérien.

Ces fonctions caractéristiques permettent alors de décrire complètement la variable aléatoire  $X$ . En effet, en développant  $\exp(j\nu x)$  dans l'équation 4.2 au voisinage de zéro et en identifiant avec le développement de Taylor de la première fonction caractéristique, on obtient les moments décentrés d'ordre  $r$  de  $X$  :

$$\mu'_{X(r)} = E[x^r] = (-j)^r \left. \frac{d^r \Phi_X(\nu)}{d\nu^r} \right|_{\nu=0} \quad (4.4)$$

Les dérivées de la seconde fonction caractéristique, prises à l'origine, définissent les cumulants :

$$\kappa_{X(r)} = (-j)^r \left. \frac{d^r \Psi_X(\nu)}{d\nu^r} \right|_{\nu=0} \quad (4.5)$$

correspondant aux coefficients du développement en série de Taylor de la seconde fonction caractéristique.

Les cumulants d'ordre  $r$  peuvent être calculés à partir des moments décentrés d'ordres inférieurs ou égal à  $r$ . Pour les quatre premiers ordres, ces relations sont [KS63] :

$$\begin{aligned} \kappa_{X(1)} &= \mu'_{X(1)} \\ \kappa_{X(2)} &= \mu'_{X(2)} - \mu'^2_{X(1)} \\ \kappa_{X(3)} &= \mu'_{X(3)} - 3\mu'_{X(1)}\mu'_{X(2)} + 2\mu'^3_{X(1)} \\ \kappa_{X(4)} &= \mu'_{X(4)} - 4\mu'_{X(3)}\mu'_{X(1)} - 3\mu'^2_{X(2)} + 12\mu'_{X(2)}\mu'^2_{X(1)} - 6\mu'^4_{X(1)} \end{aligned} \quad (4.6)$$

ce qui donne pour les moments centrés :

$$\begin{aligned}\kappa_{X(1)} &= \mu_{X(1)} \\ \kappa_{X(2)} &= \mu_{X(2)} \\ \kappa_{X(3)} &= \mu_{X(3)} \\ \kappa_{X(4)} &= \mu_{X(4)} - 3\mu_{X(2)}^2\end{aligned}\tag{4.7}$$

Une propriété intéressante des cumulants (d'ordres supérieurs ou égal à 2) est l'invariance par translation. En effet, si on note  $Y = X + T$  une nouvelle variable aléatoire, avec  $T$  déterministe d'amplitude  $t$ , la translation provoque un déphasage de la première fonction caractéristique, ce qui induit le lien entre les secondes fonctions caractéristiques de  $Y$  et de  $X$  selon la formule  $\Psi_Y(\nu) = jt\nu + \Psi_X(\nu)$ . Ceci montre bien, d'après l'équation 4.5, que la translation n'affecte que le cumulants d'ordre 1 (la moyenne). Ceci n'est bien entendu pas vrai pour les moments.

Lorsque  $X$  est une variable gaussienne, sa seconde fonction caractéristique est :

$$\Psi_X(\nu) = j\mu'_{X(1)}\nu - \frac{1}{2}\mu'_{X(2)}\nu^2\tag{4.8}$$

Nous en déduisons que les cumulants d'ordres strictement supérieurs à 2 sont nuls. Ceci caractérise la loi gaussienne.

#### 4.2.2.2 Skewness et kurtosis

Au vu des remarques faites précédemment, il apparut naturel d'évaluer la "gaussianité" d'une variable aléatoire à partir de ses cumulants. C'est ainsi qu'ont été définies deux grandeurs statistiques : le skewness et le kurtosis [LAC97].

Le skewness ou asymétrie (traduction française du mot anglais *skewness*) s'évalue selon la formule :

$$\mathcal{S}_X = \frac{\kappa_{X(3)}}{\kappa_{X(2)}^{3/2}}\tag{4.9}$$

Le dénominateur permet de raisonner sur la variable aléatoire standardisée (après centrage et normalisation). Le skewness correspond alors au cumulants d'ordre 3 de la variable  $X$  standardisée.

La définition du skewness en fonction des moments centrés s'obtient ainsi :

$$\mathcal{S}_X = \frac{\mu_{X(3)}}{\mu_{X(2)}^{3/2}}\tag{4.10}$$

Le skewness évalue l'asymétrie de la densité de probabilité associée à la variable aléatoire  $X$ . Il est nul lorsque celle-ci possède un axe de symétrie, comme la loi gaussienne. Il est strictement positif lorsque la densité de probabilité tend vers zéro plus lentement lorsque les valeurs vont vers l'infini positif que pour les valeurs allant vers l'infini négatif, et le skewness est strictement négatif dans le cas contraire.

Le kurtosis (du mot grec  $\kappa\acute{\upsilon}\rho\tau\omega\sigma\iota\varsigma$  : action de courber, convexité) s'évalue lui selon la formule :

$$\mathcal{K}_X = \frac{\kappa_{X(4)}}{\kappa_{X(2)}^2} \quad (4.11)$$

Le kurtosis correspond donc au cumulants d'ordre 4 de la variable  $X$  standardisée.

En fonction des moments centrés, nous avons :

$$\mathcal{K}_X = \frac{\mu_{X(4)}}{\mu_{X(2)}^2} - 3 \quad (4.12)$$

Le kurtosis évalue l'aplatissement de la densité de probabilité associée à la variable aléatoire  $X$ . Ainsi, ce paramètre est nul pour une loi gaussienne. Il est positif pour les densités ayant un aspect plus "pointu" que la gaussienne; il est négatif pour les densités plus "aplaties".

Ces deux grandeurs permettent donc d'évaluer l'écart d'une densité de probabilité à la loi normale. D'après les remarques faites dans le paragraphe précédent, ces grandeurs sont invariantes par translation. Les remarques sur les valeurs du skewness et du kurtosis ne sont plus valables dans le cas de densités de probabilité multimodales (ayant plusieurs maxima locaux). Dans ce cas, le calcul s'impose pour expliquer les résultats.

### 4.2.3 Estimateurs

L'estimation du skewness et du kurtosis sur un échantillon de taille finie  $n$  de  $X$  peut s'effectuer à partir des  $k$ -statistiques. La  $k$ -statistique  $k_{X(r)}$  se définit comme l'unique estimateur symétrique non biaisé du cumulants  $\kappa_{X(r)}$  sur l'échantillon [KS63]. Un estimateur du skewness est alors donné par :

$$\hat{\mathcal{S}}_X = \frac{k_{X(3)}}{k_{X(2)}^{3/2}} \quad (4.13)$$

On définit le moment centré d'ordre  $r$  de l'échantillon par l'expression :

$$\begin{aligned} \hat{\mu}_{X(r)} &= \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu}_{X(1)})^r \quad \text{pour } r \geq 2 \\ \hat{\mu}_{X(1)} &= \frac{1}{n} \sum_{i=1}^n x_i \end{aligned} \quad (4.14)$$

avec  $x_i$  les  $n$  éléments de l'échantillon de  $X$ . Considérant les relations entre  $k_{X(r)}$  et  $\hat{\mu}_{X(r)}$ , nous avons :

$$\hat{\mathcal{S}}_X = \frac{\sqrt{n(n-1)} \hat{\mu}_{X(3)}}{n-2 \hat{\mu}_{X(2)}^{3/2}} \quad (4.15)$$

De même, pour le kurtosis, un estimateur est donné par :

$$\hat{\mathcal{K}}_X = \frac{k_{X(4)}}{k_{X(2)}^2} \quad (4.16)$$

d'où l'estimateur :

$$\hat{\mathcal{K}}_X = \frac{(n+1)(n-1)\hat{\mu}_{X(4)}}{(n-2)(n-3)\hat{\mu}_{X(2)}^2} - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (4.17)$$

Les comportements statistiques de ces estimateurs ont été étudiés pour de grandes valeurs de  $n$ . Nous pouvons tout d'abord dire que ces estimateurs sont biaisés au premier ordre et sont corrélés entre eux (les biais dépendant des moments d'ordres supérieurs). Des résultats exacts peuvent cependant être donnés dans le cas gaussien. Ainsi, si l'on note  $\mathcal{M}$  et  $\mathcal{V}$  respectivement la moyenne et la variance, nous avons :

$$\begin{aligned} \mathcal{M}(\hat{\mathcal{S}}_X) &= 0 \\ \mathcal{M}(\hat{\mathcal{K}}_X) &= 0 \\ \mathcal{V}(\hat{\mathcal{S}}_X) &= \frac{6n(n-1)}{(n-2)(n+1)(n+3)} \approx \frac{6}{n} \\ \mathcal{V}(\hat{\mathcal{K}}_X) &= \frac{24n(n-1)^2}{(n-3)(n-2)(n+3)(n+5)} \approx \frac{24}{n} \end{aligned} \quad (4.18)$$

Dans le cas général, il n'existe pas d'expression analytique d'estimateurs non biaisés qui soit indépendante de la distribution de la variable aléatoire  $X$ . Mais on peut remarquer que ces estimateurs sont non biaisés dans le cas gaussien. Cependant, les variances de ces estimateurs sont assez élevées (en comparaison avec celles des estimateurs des moyenne et variance par exemple) et une bonne estimation demande donc un nombre suffisant d'échantillons.

## 4.3 Utilisation des statistiques d'ordres supérieurs pour la détection : cas gaussien

Dans cette partie, nous allons nous intéresser à l'utilisation des grandeurs définies plus haut dans la détection de régions déterministes de petite taille entourées d'un bruit gaussien. Ceci est utilisé comme première étape dans le développement d'une méthode de détection d'échos dans les images sonar que nous allons voir dans la partie suivante.

Pour illustrer le propos, la méthode est testée sur une image synthétique (de  $128 \times 128$  pixels), consistant en un carré (de taille  $11 \times 11$ ), avec une amplitude  $D$ , entouré par un fond bruité gaussien centré.

### 4.3.1 Propriétés locales des SOS

#### 4.3.1.1 Modélisation statistique

Le fond bruité de l'image servant de modèle suit une loi gaussienne centrée de variance  $\sigma_B^2$ . Sa densité de probabilité s'écrit alors :

$$\mathcal{G}_B(B) = \frac{1}{\sigma_B \sqrt{2\pi}} \exp\left(-\frac{B^2}{2\sigma_B^2}\right) \quad (4.19)$$

et ses moments décentrés d'ordre  $r$  sont donnés par :

$$\begin{aligned} \mu'_{B(r)} &= \sigma_B^r \frac{r!}{(r/2)! 2^{r/2}} \quad \text{pour } r \text{ paire,} \\ &= 0 \quad \text{sinon} \end{aligned} \quad (4.20)$$

Nous pouvons remarquer que ces moments décentrés conduisent à la nullité du skewness et du kurtosis pour une distribution gaussienne.

En ce qui concerne le carré déterministe d'amplitude  $D$ , ses moments décentrés d'ordre  $r$  se calculent comme suit (voir l'équation 3.6) :

$$\mu'_D(r) = D^r \quad (4.21)$$

En reprenant le formalisme du chapitre 3, nous définissons le Rapport Signal à Bruit (RSB) :

$$\rho = \frac{D}{\sigma_B} \quad (4.22)$$

et en décibels :

$$\rho_{dB} = 10 \log_{10} \left( \frac{D^2}{\sigma_B^2} \right) = 20 \log_{10}(\rho) \quad (4.23)$$

Etant donnée la propriété d'invariance par translation du skewness et du kurtosis vue plus haut, si le fond bruité est modélisé par une gaussienne non centrée de moyenne  $\mu_B$  et de variance  $\sigma_B$ , décrite par la densité de probabilité :

$$\mathcal{G}'_B(B) = \frac{1}{\sigma_B \sqrt{2\pi}} \exp\left\{-\frac{(B - \mu_B)^2}{2\sigma_B^2}\right\} \quad (4.24)$$

tous les résultats décrits par la suite restent valables avec un RSB défini par :

$$\rho = \frac{|D - \mu_B|}{\sigma_B} \quad (4.25)$$

#### 4.3.1.2 Evaluation locale des SOS

Le skewness et le kurtosis décrits ci-dessus (paragraphe 4.2.2.2) sont ici utilisés dans le but de détecter de petites régions déterministes dans une image bruitée. Pour cela, ces grandeurs sont évaluées localement pour chaque pixel en utilisant une fenêtre carrée glissante, composée de  $n$  pixels, le pixel courant étant au centre.  $p \in [0, 1]$  est défini comme la proportion de pixels déterministes dans la fenêtre de calcul (même définition que dans le chapitre 3 : voir la figure 3.1). On suppose également que les modèles statistiques associés à la région déterministe et au fond bruité sont les mêmes au niveau de la fenêtre de calcul

qu'au niveau de l'image en entier. Ceci est vérifié quand la taille de la fenêtre est suffisamment élevée. Cette taille doit être plus importante que celle des régions déterministes recherchées.

Si l'on note  $\mu'_{D(r)}$ ,  $\mu'_{B(r)}$  et  $\mu'_{F(r)}$  les moments décentrés d'ordre  $r$  de respectivement la "partie déterministe", la "partie fond" et l'ensemble de la fenêtre, nous avons (équation 3.3) :

$$\mu'_{F(r)} = p \cdot \mu'_{D(r)} + (1 - p) \cdot \mu'_{B(r)} \quad (4.26)$$

D'après la relation 4.20, nous avons  $\mu'_{B(2)} = \sigma_B^2$ ,  $\mu'_{B(4)} = 3\sigma_B^4$  et  $\mu'_{B(1)} = \mu'_{B(3)} = 0$ , ce qui donne, en utilisant en outre la relation 4.21 :

$$\begin{aligned} \mu'_{F(1)} &= pD \\ \mu'_{F(2)} &= pD^2 + (1 - p)\sigma_B^2 \\ \mu'_{F(3)} &= pD^3 \\ \mu'_{F(4)} &= pD^4 + 3(1 - p)\sigma_B^4 \end{aligned} \quad (4.27)$$

Ce qui aboutit, en utilisant les relations de l'équation 4.6, à :

$$\begin{aligned} \kappa_{F(2)} &= (1 - p)(pD^2 + \sigma_B^2) \\ \kappa_{F(3)} &= p(1 - p)[(1 - 2p)D^3 - 3D\sigma_B^2] \\ \kappa_{F(4)} &= p(1 - p)[(1 - 6p + 6p^2)D^4 - (1 - 2p)D^2\sigma_B^2 + 3\sigma_B^4] \end{aligned} \quad (4.28)$$

En incluant le RSB  $\rho$  dans les relations précédentes, nous trouvons alors les expressions suivantes pour le skewness et le kurtosis sur la fenêtre de calcul, en fonction de  $p$  et de  $\rho$  :

$$\mathcal{S}_F(\rho, p) = \frac{p}{\sqrt{1 - p}} \frac{(1 - 2p)\rho^3 - 3\rho}{(p\rho^2 + 1)^{3/2}} \quad (4.29)$$

$$\mathcal{K}_F(\rho, p) = \frac{p}{1 - p} \frac{(1 - 6p + 6p^2)\rho^4 - 6(1 - 2p)\rho^2 + 3}{(p\rho^2 + 1)^2} \quad (4.30)$$

Les variations de ces grandeurs en fonction de  $p$  et du RSB  $\rho$  sont représentées sur la figure 4.1. Nous pouvons donc remarquer que le comportement de ces valeurs est différent selon que le RSB est élevé ou faible. Le skewness a des valeurs faibles pour un RSB faible. Dans le cas d'un RSB élevé, il a des valeurs élevées en absolu, mais positives dans le cas de faibles  $p$ , et négatives pour des  $p$  élevées (proches de 1). Ceci est confirmé par la figure 4.2(a) sur laquelle nous pouvons voir le skewness tendre vers zéro pour de faibles RSB (inférieurs à 0dB pour de faibles  $p$  et  $-20dB$  pour des valeurs de  $p$  plus élevées) et prendre des valeurs élevées pour des RSB importants (supérieurs à 20dB). Des valeurs intermédiaires sont obtenues pour des valeurs "moyennes" du RSB.

En ce qui concerne le kurtosis (voir la figure 4.2(b)), le comportement est opposé selon que l'on ait un RSB élevé ou faible, avec un cas intermédiaire entre 0 et 20dB.

Tenant compte de ces observations, le problème de détection est décomposé en trois sections, selon que l'on est dans le cas d'un RSB faible, élevé ou intermédiaire.

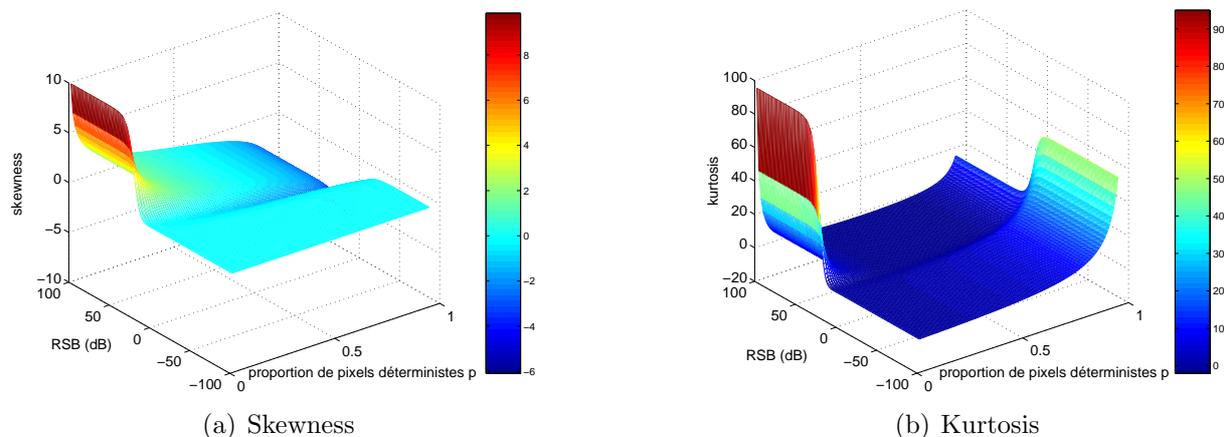


FIG. 4.1 – Valeurs des skewness et kurtosis en fonction de la proportion de pixels déterministes  $p$  et du RSB.

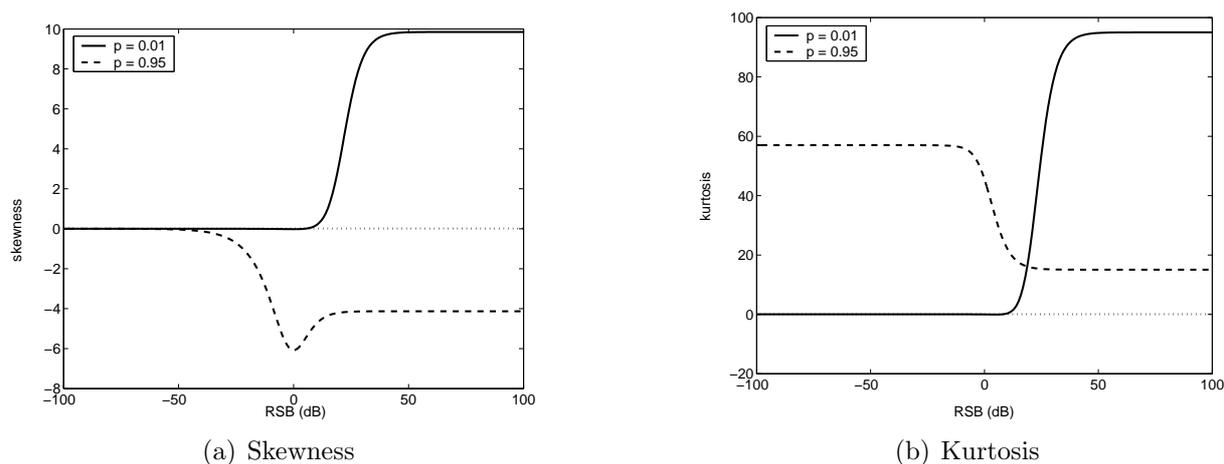


FIG. 4.2 – Valeurs des skewness et kurtosis en fonction du RSB pour des valeurs de  $p$  faibles (trait continu) ou élevées (traits pointillés).

### 4.3.2 Application à la détection de petits objets : cas des RSB faibles

Dans ce paragraphe, nous considérons des images contenant de petits objets (échos, défauts, etc. modélisés comme des régions de petite taille), avec un rapport signal à bruit faible comme il est mentionné plus haut à partir de la figure 4.2. Sont alors considérés comme faibles les RSB inférieurs à  $-20\text{dB}$ . A titre d'illustration, les SOS sont estimées sur une image de synthèse, comme décrit précédemment, avec un RSB égal à  $-60\text{dB}$  (figure 4.5(a)).

### 4.3.2.1 Approximations

Pour des valeurs faibles du rapport signal à bruit, les expressions présentées dans le paragraphe précédent (équations 4.29 et 4.30) peuvent être approchées par les relations suivantes :

$$\mathcal{S}_F(p) \approx \lim_{\rho \rightarrow 0} \mathcal{S}_F(\rho, p) = 0 \quad (4.31)$$

$$\mathcal{K}_F(p) \approx \lim_{\rho \rightarrow 0} \mathcal{K}_F(\rho, p) = \frac{3p}{1-p} \quad (4.32)$$

Ces approximations sont confirmées par la figure 4.3. En effet, nous pouvons voir que pour un RSB de -60dB, le kurtosis croît de zéro à l'infini quand  $p$  va de zéro à un, et le skewness reste proche de zéro. Ce résultat est illustré sur la figure 4.4 montrant un exemple de densité de probabilité obtenue sur une fenêtre de calcul avec un faible RSB (cette figure n'est pas issue d'un résultat réel, mais a été construite manuellement dans un objectif d'illustration). Elle montre donc une densité symétrique, expliquant la nullité du skewness, avec un pic, conduisant à un kurtosis positif élevé (voir les remarques faites dans le paragraphe 4.2.2.2).

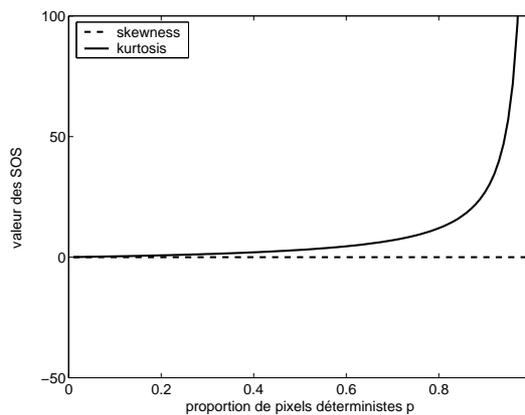


FIG. 4.3 – Skewness (traits pointillés) et kurtosis (trait continu) en fonction du paramètre  $p$  pour un RSB de -60dB.

### 4.3.2.2 Résultats obtenus

Les approximations effectuées précédemment expliquent également les résultats obtenus sur l'image synthétique (figure 4.5). Remarquons que sur notre exemple, la région déterministe est assez visible à l'oeil nu, ceci dans un but d'illustration. Mais, nous devons insister sur le fait que dans un cas réel, les régions d'intérêt peuvent être composées d'un très petit nombre de pixels dans une image de taille élevée, avec donc une visibilité moindre. L'image des skewness (figure 4.5(b)) est seulement composée de valeurs très

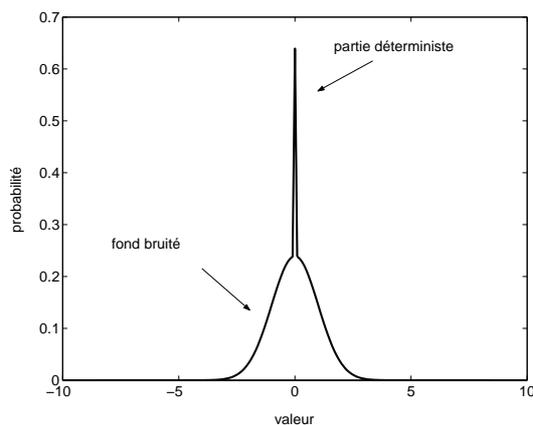


FIG. 4.4 – Exemple de densité de probabilité sur une fenêtre de calcul pour un RSB faible ( $p = 0,4$ ).

faibles (proches de zéro), aucune région ne ressortant du fond bruité. A l’opposé, le kurtosis donne des valeurs faibles dans les régions correspondant au fond bruité, et des valeurs plus élevées autour du centre de la région déterministe. ceci vient du fait que le kurtosis augmente avec  $p$  et, par conséquent, plus la fenêtre de calcul est proche du centre de l’objet, plus la proportion de pixels déterministes  $p$  est élevée. Nous pouvons remarquer que les approximations faites précédemment restent valides dans le cas où aucune région déterministe n’est présente (par exemple dans le fond bruité, avec  $p = 0$ ). On retrouve donc bien la nullité du kurtosis pour un phénomène gaussien. Ainsi, dans le cas d’un faible RSB, la détection de la région recherchée peut se faire en effectuant un simple seuillage sélectionnant les valeurs non nulles du kurtosis (à la variance de l’estimateur près). Par contre, le skewness ne nous permettra pas d’avoir une détection satisfaisante.

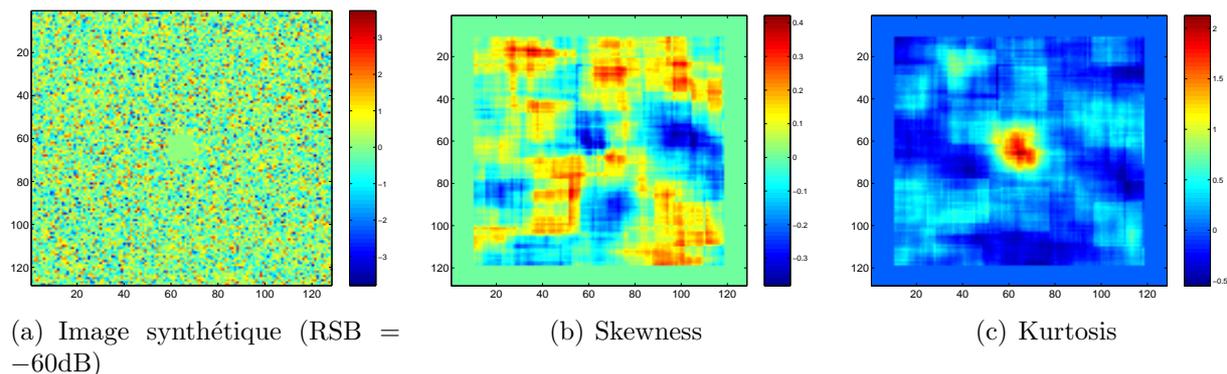


FIG. 4.5 – Images des SOS évaluées sur une fenêtre  $21 \times 21$ .

Etant donnée l’influence du paramètre  $p$  sur le kurtosis, plus la taille de la fenêtre de calcul est faible, plus la valeur du kurtosis est élevée et meilleure est la détection. Ceci est illustrée sur la figure 4.6 sur laquelle nous pouvons voir des valeurs plus élevées, et plus

centrées autour de la région déterministe, pour une fenêtre  $13 \times 13$  que pour une fenêtre  $41 \times 41$ .

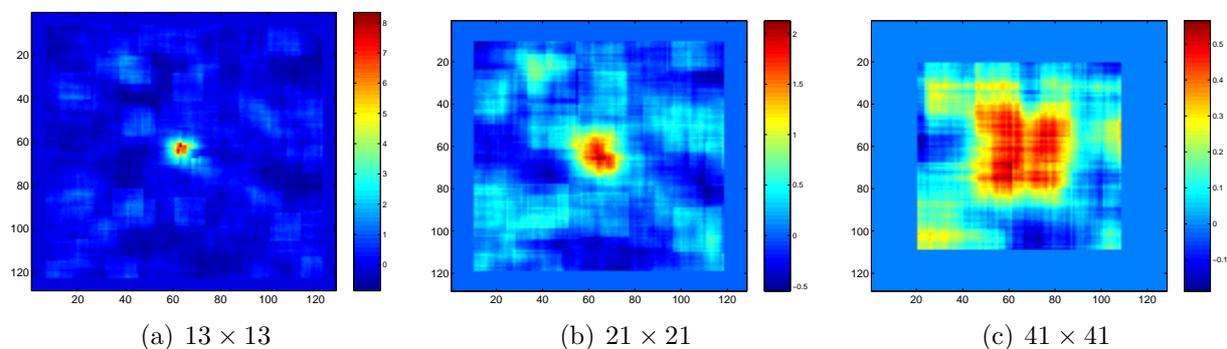


FIG. 4.6 – Images des kurtosis obtenues pour différentes tailles de fenêtres (RSB = -60dB).

### 4.3.2.3 Evaluation numérique des résultats

Afin de mettre en évidence ces observations, nous nous donnons deux critères numériques évalués sur les résultats. Le premier est la variance des valeurs des SOS sur le fond. Pour ce faire, nous considérons comme appartenant au fond les pixels résultant du calcul des SOS sur les fenêtres ne contenant aucun pixel associé à la région déterministe. Le deuxième critère est une grandeur liée au contraste, correspondant au rapport de la valeur maximale des pixels de l'image des SOS (en valeurs absolues) sur l'écart-type du fond (racine carrée de la variance précédemment calculée). Ce dernier paramètre permettra d'évaluer la qualité de détection en estimant l'ampleur de la mise en évidence de la région d'intérêt par rapport au fond. Le tableau 4.1 présente les résultats obtenus sur les images des SOS calculées avec un RSB de -60dB et différentes tailles de fenêtres de calcul.

TAB. 4.1 – Comparaison des performances de détection des SOS (variance du fond et contraste), pour un RSB de -60dB, en fonction de la taille de la fenêtre de calcul.

Taille de la fenêtre	skewness		kurtosis	
	variance	contraste	variance	contraste
$13 \times 13$	0,0282	7,94	0,115	24,6
$21 \times 21$	0,0099	4,23	0,0375	11,0
$41 \times 41$	0,0011	5,42	0,0039	8,99

Comme nous l'avons vu dans le paragraphe 4.2.3, plus la taille de la fenêtre de calcul est faible (et donc plus le nombre d'échantillons est faible), plus la variance des estimateurs du skewness et du kurtosis est élevée, d'où une augmentation de la variance du fond sur les images des SOS. Celle-ci est d'ailleurs supérieure pour le kurtosis, comme le laissait prévoir

l'équation 4.18 (d'un rapport 4 environ, surtout pour les grandes tailles de fenêtre). Nous pouvons cependant remarquer que les variances sont toujours largement inférieures à celle de l'image d'origine qui était de 1, le bruit étant généré par une loi gaussienne d'écart-type unitaire. De plus, les valeurs des contrastes confirment nos observations visuelles, concernant le kurtosis, selon lesquelles la détection est meilleure pour de faibles tailles de fenêtre de calcul. Pour le skewness, les faibles valeurs de contrastes, qui de plus semblent ne pas dépendre de la taille de la fenêtre, confirment l'inefficacité du skewness dans la détection.

Pour conclure avec la détection dans le cas d'un RSB faible, nous pouvons tout d'abord dire que le skewness est inutile dans ce cas, ses valeurs restant proches de zéro qu'il y ait un élément déterministe ou pas. Par contre, le kurtosis donne des résultats intéressants pour la détection. La taille de la fenêtre de calcul doit alors être la plus faible possible afin d'avoir le meilleur contraste et donc la meilleure détection possible. Veillons cependant à avoir une taille de fenêtre supérieure à celle de la région recherchée, afin d'éviter la nullité du dénominateur dans le calcul du kurtosis. Il nous faut également une taille suffisamment importante afin d'avoir une région de valeurs élevées de grandeur raisonnable pour une détection efficace (quelques points brillants parsemés ne seraient aucunement significatifs).

### 4.3.3 Application à la détection de petits objets : cas des RSB élevés

Dans ce paragraphe, nous considérons le cas des images contenant de petits objets avec un RSB élevé. Comme nous le montrent les courbes de la figure 4.2, nous considérons comme élevés des RSB supérieurs à 40dB. A titre d'illustration, les SOS sont estimées sur une image synthétique avec un RSB de 50dB (figure 4.8(a)).

#### 4.3.3.1 Approximations

Dans le cas de RSB élevés, nous pouvons effectuer les approximations suivantes à partir des expressions 4.29 et 4.30 :

$$\mathcal{S}_F(p) \approx \lim_{\rho \rightarrow +\infty} \mathcal{S}_F(\rho, p) = \frac{1 - 2p}{\sqrt{p(1 - p)}} \quad (4.33)$$

$$\mathcal{K}_F(p) \approx \lim_{\rho \rightarrow +\infty} \mathcal{K}_F(\rho, p) = \frac{1 - 6p + 6p^2}{p(1 - p)} \quad (4.34)$$

Ceci est illustré sur la figure 4.7. Pour un RSB de 50dB, le kurtosis décroît de l'infini à  $-2$  quand  $p$  augmente de 0 à 0,5. Il croît à nouveau vers l'infini quand  $p$  augmente de 0,5 à 1. Le skewness a lui un comportement différent : il décroît de plus l'infini à moins l'infini quand  $p$  va de 0 à 1, avec un passage par zéro en  $p = 0,5$ .

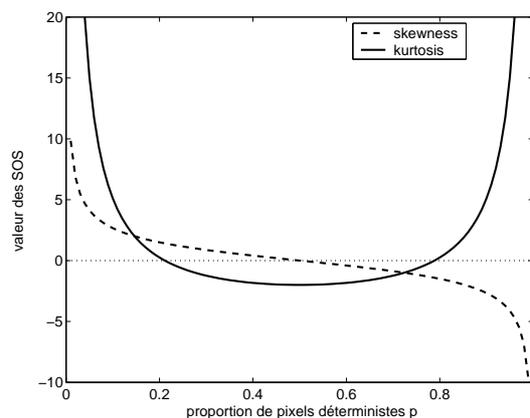


FIG. 4.7 – Skewness (traits pointillés) et kurtosis (trait continu) en fonction du paramètre  $p$  pour un RSB de 50dB.

#### 4.3.3.2 Résultats obtenus

La figure 4.8 présente les résultats obtenus respectivement avec le skewness (figure 4.8(b)) et le kurtosis (figure 4.8(c)) dans le cas d'une image avec un RSB élevé (figure 4.8(a)). Nous pouvons alors faire ces observations :

- Dans le fond bruité, les SOS ont des valeurs faibles. Ceci correspond à la nullité des SOS pour une distribution gaussienne. On peut remarquer que dans ce cas, les approximations faites dans les relations 4.33 et 4.34 ne sont plus valables, le RSB  $\rho$  tendant, dans ce cas, vers zéro.
- Des structures en forme de carrés peuvent être observées autour de la région déterministe. Ceux-ci sont constitués de pixels de valeurs élevées, la valeur la plus élevée étant dans les coins.

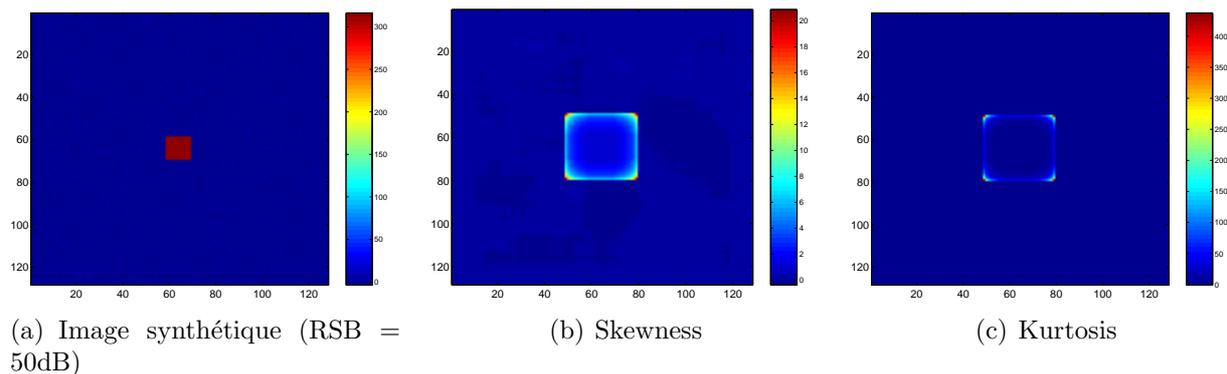


FIG. 4.8 – Images des SOS évaluées sur une fenêtre  $21 \times 21$ .

La taille de ces carrés correspond à la taille de la région déterministe additionnée à celle de la fenêtre de calcul. Si on note  $n_D$  la longueur (respectivement la largeur) de la région déterministe, et  $n_F$  la longueur (respectivement la largeur) de la fenêtre de calcul,

la longueur (respectivement la largeur)  $n_R$  de la structure en forme de rectangle observée est donnée par :

$$n_R = n_D + n_F - 1 \quad (4.35)$$

Par exemple, sur la figure 4.8, on a une structure de taille  $31 \times 31$ , à partir d'une région déterministe  $11 \times 11$  et une fenêtre de calcul  $21 \times 21$ .

Comme nous pouvons le voir sur la figure 4.7, les grandeurs atteignent leur valeur maximale pour des valeurs de  $p$  minimales. Ceci correspond au cas où un seul pixel déterministe est inclus dans la fenêtre de calcul, c'est à dire quand la fenêtre de calcul glissante commence à recouvrir la région déterministe par l'un de ses coins, d'où les valeurs maximales aux coins du rectangle. Quand le nombre de pixels déterministes inclus dans la fenêtre de calcul augmente, c'est à dire quand la fenêtre glisse en direction du centre de l'objet, les valeurs des SOS décroissent. Ceci explique la forme des rectangles observés dans les images résultantes et les valeurs décroissant le long des côtés et à l'intérieur de chacun des rectangles. A partir des équations 4.33 et 4.34, pour des valeurs faibles de  $p$ , le skewness peut être approché par  $1/\sqrt{p}$  et le kurtosis par  $1/p$ . Ceci explique que pour une fenêtre de calcul  $21 \times 21$ , la valeur maximale du skewness est proche de 21 (correspondant à  $p = \frac{1}{21 \times 21}$ ) et 441 pour le kurtosis.

En conséquence, plus la taille de la fenêtre de calcul est élevée, plus la valeur maximale du skewness et du kurtosis est élevée. La figure 4.9 illustre l'effet de la taille de cette fenêtre sur les résultats du kurtosis (les résultats obtenus avec le skewness étant comparables, en tenant compte de ses propres propriétés décrites ci-dessus) : plus la taille de la fenêtre de calcul est grande, plus la taille du rectangle résultant est élevée et plus la valeur maximale du SOS est elle-même élevée (regarder les différences d'échelle). Quand  $p$  passe au-dessus de 0,5 (la fenêtre de calcul contient alors plus de pixels appartenant à la région déterministe qu'au fond bruité), le kurtosis commence à remonter, ce qui explique les valeurs croissantes vers le centre de la région déterministe (figure 4.10(b)). Par contre, pour le skewness, les valeurs deviennent négatives (figure 4.10(a)). Pour éviter ce cas, nous utilisons une fenêtre de calcul deux fois plus grande que la taille maximale des régions déterministes recherchées. Etant donné que l'on s'intéresse à la détection d'objets de petite dimension, cette condition sera facile à respecter.

Les contrastes relevés dans le tableau 4.2 confirment ces observations avec un contraste augmentant avec la taille de la fenêtre de calcul. Etant évaluées sur le fond bruité de l'image, les variances calculées dans le tableau 4.1 sont indépendantes du RSB. Le contraste sur l'image originale correspondant au RSB (soit environ 316,2 pour 50dB), nous pouvons alors remarquer que celui obtenu avec les SOS est largement supérieur, du moins pour une taille de fenêtre de calcul suffisamment importante. Ceci met en évidence l'intérêt d'une détection basée sur ces grandeurs statistiques. Enfin, notons que les contrastes obtenus avec le kurtosis, pour une taille de fenêtre donnée, sont supérieurs à ceux du skewness. Ceci s'explique par les approximations faites dans ce paragraphe (équations 4.33 et 4.34, voir également la figure 4.7) qui donnent des valeurs plus grandes pour le kurtosis que pour le skewness pour des proportions  $p$  suffisamment faibles (inférieures à 0,15 environ,  $\frac{2-\sqrt{2}}{4}$

exactement).

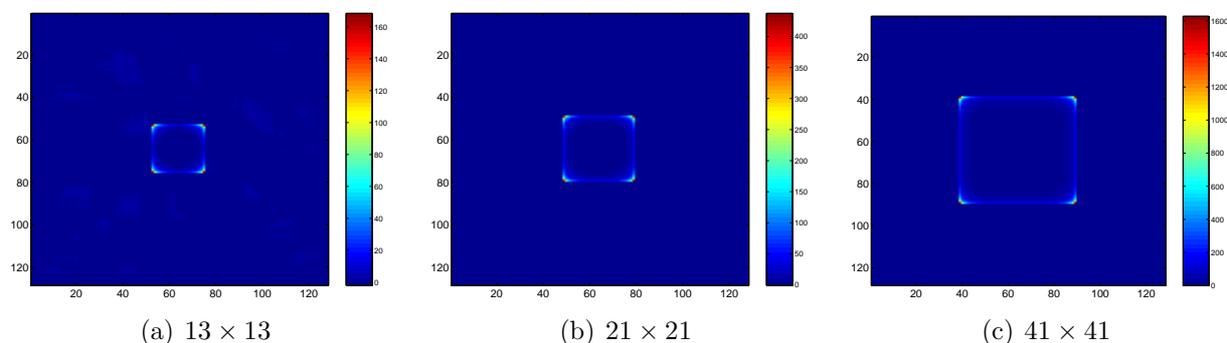


FIG. 4.9 – Images des kurtosis obtenues pour différentes tailles de fenêtre (RSB = 50dB).

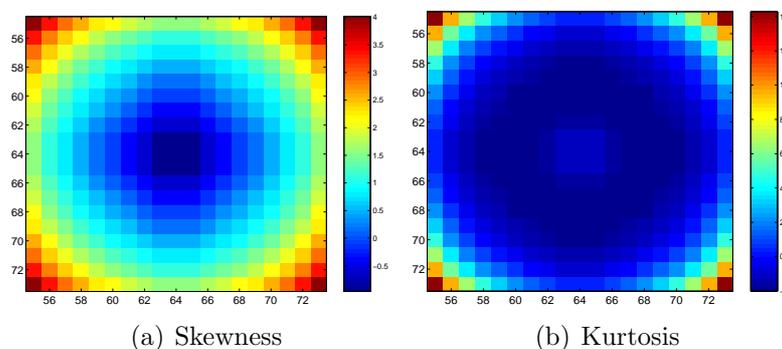


FIG. 4.10 – Zoom sur les images des SOS obtenues pour une fenêtre  $13 \times 13$  (RSB = 50dB).

TAB. 4.2 – Comparaison des contrastes des SOS, pour un RSB de 50dB ( $\approx 316,2$ ), en fonction de la taille de la fenêtre de calcul.

Taille de la fenêtre	Contrastes	
	skewness	kurtosis
$13 \times 13$	77,3	496,2
$21 \times 21$	209,4	2270,9
$41 \times 41$	1195,4	$2,59 \cdot 10^4$

Comme nous l'avons déjà dit dans le paragraphe 4.2.3, l'utilisation d'une fenêtre de calcul trop petite ne conduit pas à une bonne détection, la variance de l'estimateur étant trop importante. Cependant, la taille de la fenêtre ne doit pas non plus être trop élevée. En effet, nous avons également vu que la taille de la structure rectangulaire sur les images des SOS est égale à la taille de la région déterministe additionnée à celle de la fenêtre de calcul. Si une image contient plusieurs régions d'intérêt, les structures correspondantes sur les images

SOS peuvent alors se superposer si la fenêtre de calcul est trop grande. Cette situation est illustrée sur la figure 4.11 avec une image contenant deux régions d'amplitudes et de tailles différentes ( $5 \times 5$  pour la région de gauche,  $11 \times 11$  pour celle de droite), avec un intervalle de 21 pixels entre les deux régions. Nous pouvons également remarquer l'indépendance de la valeur maximale du kurtosis vis à vis du RSB, les deux régions conduisant à la même valeur.

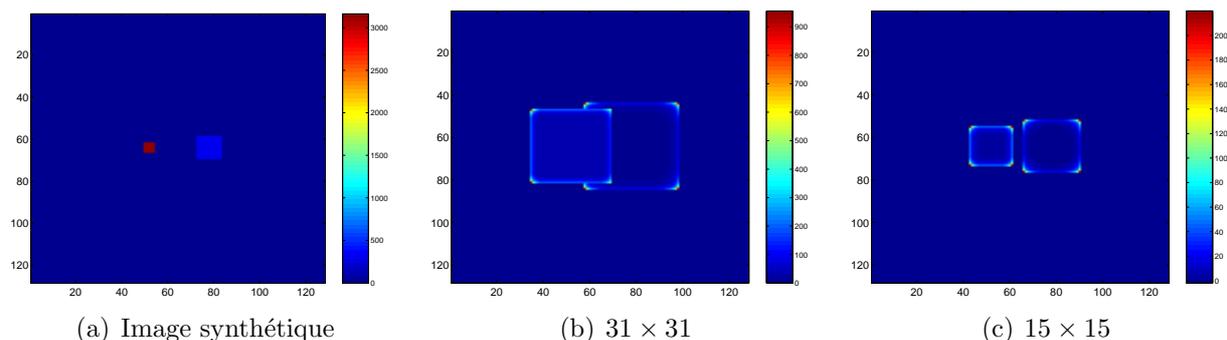


FIG. 4.11 – Images des kurtosis obtenues pour différentes tailles de fenêtre sur une image contenant deux régions déterministes (RSB = 70dB à gauche, RSB = 50dB à droite).

Pour conclure cette partie, nous pouvons dire que dans le cas d'un RSB élevé, le skewness et le kurtosis permettent tous les deux la détection de régions déterministes, le kurtosis fournissant *a priori* des résultats plus intéressants. Cependant, les valeurs maximales étant dans les coins d'une structure rectangulaire entourant la région recherchée, les résultats doivent être focalisés afin d'avoir la position précise de la région. Ceci fera l'objet du paragraphe 4.3.5. Enfin, le choix de la taille de la fenêtre de calcul est un compromis entre le pouvoir de détection (plus la fenêtre est grande, meilleure est la détection) et le pouvoir de résolution (plus la fenêtre est grande et plus il y a risque de chevauchement entre les structures provenant d'objets différents).

### 4.3.4 Application à la détection de petits objets : cas des RSB intermédiaires

Sont considérés comme intermédiaires les RSB entre -20dB et 40dB. Comme nous pouvons le voir sur la figure 4.2, les performances de détection restent intéressantes pour ces valeurs de RSB, mais elles deviennent plus compliquées à évaluer et à comprendre.

#### 4.3.4.1 Skewness

Les valeurs du skewness restent proches de zéro, jusqu'à un RSB d'environ 10dB, pour des valeurs de  $p$  faibles. Par contre, pour des  $p$  élevés, il prend des valeurs négatives à partir d'environ -50dB, avec un pic à 0dB. Ainsi, pour un RSB entre -50dB et 10dB, la détection peut s'effectuer grâce à l'image des skewness en isolant les pixels négatifs (à la

variance de l'estimateur près). Ils sont situés à proximité du centre de la région déterministe (voir la figure 4.12(b)). Si l'on ne connaît pas le RSB *a priori*, il serait intéressant de raisonner sur les valeurs absolues. On isolerait alors les pixels de valeurs élevées dans tous les cas. Pour des RSB plus élevés, le skewness augmente régulièrement jusqu'à atteindre les approximations faites dans l'équation 4.33. Pour ces RSB (entre 10dB et 40dB), nous retrouvons les structures rectangulaires décrites dans le paragraphe précédent (voir les figures 4.13(b) et 4.8(b)), avec des valeurs diminuant plus lentement en direction du centre de la région. Dans ce cas, la méthode de détection est la même que pour les RSB élevés.

#### 4.3.4.2 Kurtosis

Le comportement du kurtosis est similaire à celui obtenu avec un RSB faible jusqu'à environ 10dB avec des valeurs décroissant progressivement dans le cas d'un  $p$  élevé (figure 4.2(b)). La détection peut alors se faire en sélectionnant les pixels ayant les valeurs les plus élevées dans l'image des kurtosis : ils sont localisés à proximité du centre de la région d'intérêt (figure 4.12(c)). Ce cas est similaire à celui d'un RSB faible (figure 4.6(a)), mais le contraste entre les valeurs les plus élevées et le fond bruité est plus faible. Pour des RSB plus hauts (supérieurs à 10dB), le kurtosis augmente progressivement, pour des  $p$  faibles, pour atteindre les approximations faites dans le cas d'un RSB élevé. les structures rectangulaires réapparaissent alors (figure 4.13(c)), avec des valeurs décroissant plus lentement en direction du centre, mais avec la même structure qu'avec des RSB élevés. La méthode de détection est alors à nouveau identique à celle effectuée pour des RSB élevés.

Les résultats numériques relevés dans les tableaux 4.3 et 4.4 confirment les observations précédentes avec un comportement de "RSB faible" à 0dB pour le kurtosis et de "RSB élevé" à 20dB pour les deux grandeurs. Notons toutefois que les contrastes obtenus sont inférieurs dans ces deux cas à ceux obtenus dans les études précédentes, mais ils restent largement supérieurs aux RSB de l'image originale correspondante. Il faut également remarquer que le skewness devient intéressant pour la détection à 0dB.

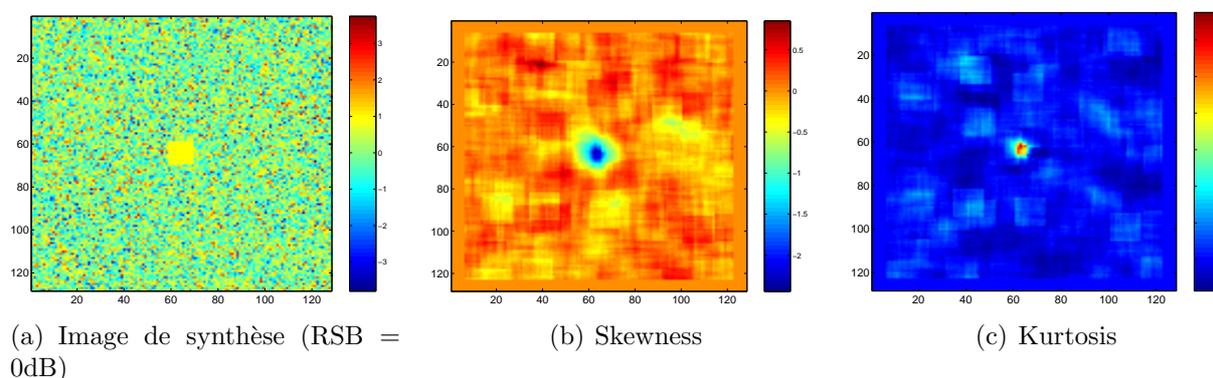


FIG. 4.12 – Images des SOS évaluées sur une fenêtre  $13 \times 13$ .

TAB. 4.3 – Comparaison des contrastes des SOS, pour un RSB de 0dB (= 1), en fonction de la taille de la fenêtre de calcul.

Taille de la fenêtre	Contrastes	
	skewness	kurtosis
13 × 13	14,5	19,9
21 × 21	8,39	4,46
41 × 41	6,84	5,21

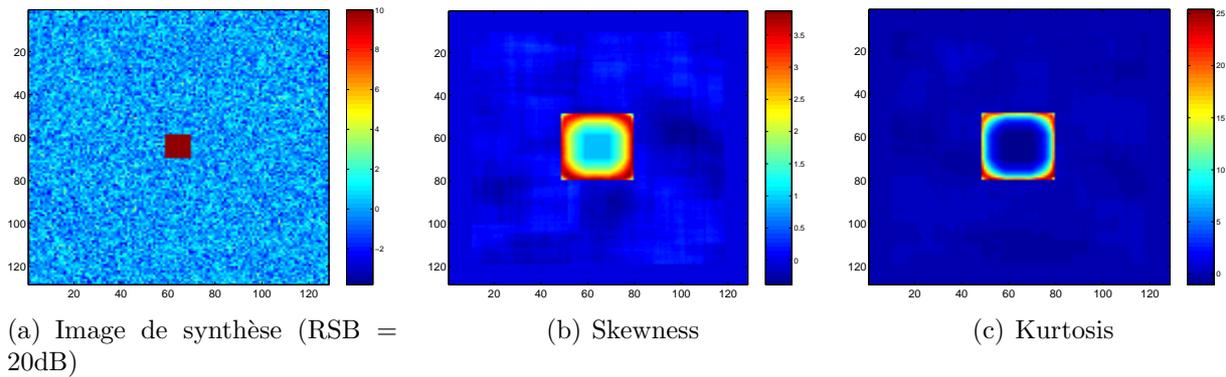


FIG. 4.13 – Images des SOS évalués sur une fenêtre 21 × 21.

TAB. 4.4 – Comparaison des contrastes des SOS, pour un RSB de 20dB (= 10), en fonction de la taille de la fenêtre de calcul.

Taille de la fenêtre	Contrastes	
	skewness	kurtosis
13 × 13	24,4	75,5
21 × 21	38,8	131,3
41 × 41	113,3	384,5

### 4.3.5 Détection avec un RSB élevé : focalisation et reconstruction de la région déterministe

Dans le cas d'un RSB élevé, ou, du moins, supérieur à 10dB, des formes carrées apparaissent sur les images des skewness et des kurtosis autour des régions recherchées, les valeurs les plus élevées étant aux coins de ces carrés. Contrairement à la méthode de détection basée sur les deux premiers ordres statistiques et présentée dans le chapitre 3, les SOS ne permettent donc pas une localisation exacte directe des objets présents dans l'image. Pour résoudre ce problème, nous proposons une approche utilisant un filtre adapté permettant de focaliser les valeurs vers le centre des régions recherchées (paragraphes 4.3.5.1

et 4.3.5.2), puis nous “reconstruirons” la région déterministe en utilisant une dilatation (paragraphe 4.3.5.3).

#### 4.3.5.1 Focalisation : approche par filtrage adapté

Dans ce paragraphe, nous cherchons à focaliser les résultats des SOS afin d'améliorer le positionnement des régions recherchées. Notre objectif est donc de ramener les valeurs élevées, qui se trouvent sur une structure rectangulaire telle que décrite plus haut, vers le centre de la région déterministe. Pour cela, nous utilisons une approche par filtrage adapté en effectuant la corrélation entre l'image des SOS et un modèle théorique de résultat. Les résultats obtenus seront présentés dans cette partie seulement sur les images des kurtosis, les résultats obtenus avec les skewness étant similaires, en utilisant, bien sûr, le modèle théorique adéquat.

Si l'on connaît la taille de la fenêtre de calcul ayant permis de construire l'image des SOS, et si l'on a également une idée approchée de la taille des objets recherchés, les approximations faites dans les équations 4.33 et 4.34 peuvent être utilisées pour construire le modèle théorique. Par exemple, pour l'image des kurtosis présentée sur la figure 4.15(a), le modèle théorique calculé est montré sur la figure 4.14 (avec une taille  $31 \times 31$  comme le prévoit l'équation 4.35). Le modèle théorique ainsi construit équivaut donc au résultat que l'on obtient pour un RSB élevé, ce qui correspond approximativement à la figure 4.15(a).

La figure 4.15(b) montre le résultat obtenu par la corrélation de l'image des kurtosis avec le modèle, ce qui correspond à un filtrage adapté. Sur l'image zoomée (figure 4.15(c)), nous pouvons voir que le maximum de l'image filtrée est situé exactement au centre de la région déterministe de l'image d'origine. Un simple seuillage de cette image filtrée permet une détection aisée et précise de la région recherchée. D'autres connaissances sur les caractéristiques des régions d'intérêt peuvent être incorporées au modèle théorique : par exemple, une forme rectangulaire pourrait être utilisée à la place d'un carré, une structure ayant une orientation particulière (autre qu'horizontale ou verticale) est également possible.

Nous pouvons remarquer sur les résultats filtrés une structure en forme de croix. Cette forme provient des caractéristiques morphologiques du modèle théorique et du carré (l'autocorrélation d'une forme rectangulaire est non négligeable en dehors de la valeur zéro). De plus, notons que dans l'algorithme de filtrage, le résultat est normalisé par rapport à la valeur en zéro de l'autocorrélation du modèle théorique, ceci afin d'avoir un résultat indépendant de la taille de la fenêtre de calcul. Ceci explique la valeur maximale de 1 sur le résultat du filtrage (figure 4.15(c)). Nous pouvons cependant remarquer que cette valeur est bien inférieure à 1 dans le cas d'une corrélation avec un simple carré. En effet, le carré utilisé a pour valeur la valeur maximale théorique du kurtosis (441 par exemple pour une fenêtre de calcul  $21 \times 21$ ) le long de ses arêtes, sur une épaisseur de un pixel. Ce modèle est assez éloigné du résultat, ce qui explique une corrélation faible, mais cependant intéressante, la valeur de la corrélation étant quasiment nulle en dehors de la région recherchée (à la structure en forme de croix près).

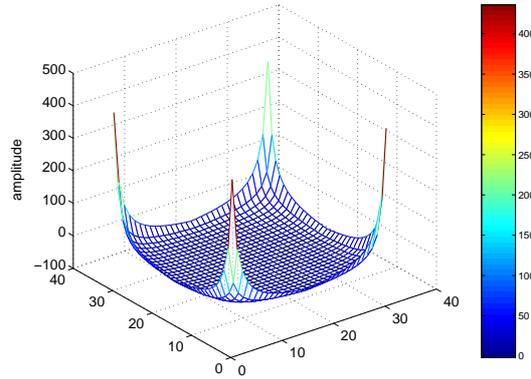


FIG. 4.14 – Modèle théorique du kurtosis utilisé pour le filtre adapté (fenêtre  $31 \times 31$ , région déterministe  $11 \times 11$ ).

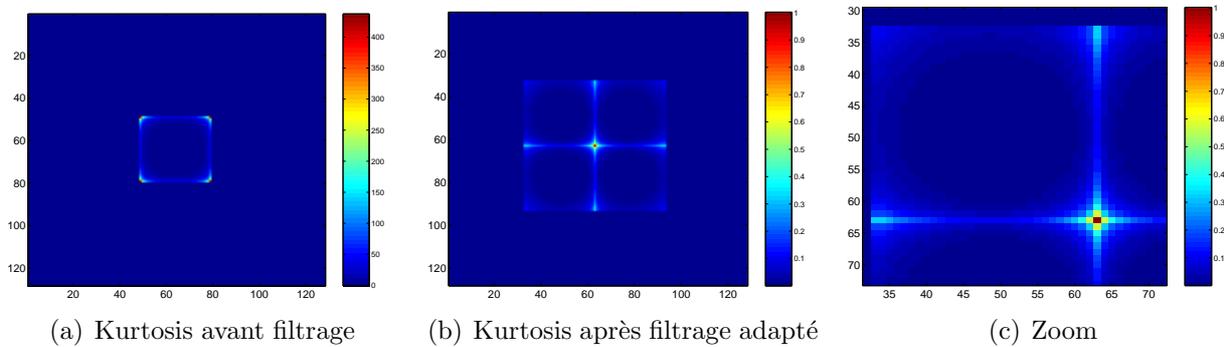


FIG. 4.15 – Focalisation par filtrage adapté sur l'image des kurtosis (fenêtre  $21 \times 21$ ).

#### 4.3.5.2 Prise en compte de l'incertitude sur la taille des régions d'intérêt

La taille de la fenêtre de calcul est connue (elle est fixée par l'utilisateur, en fonction de la résolution, de l'espace approché entre les objets,...), mais la taille des régions recherchées n'est pas connue précisément. En conséquence, la taille des structures sur les images des SOS, qui doivent être focalisées, est mal connue. Une solution est alors de prendre, pour le filtre adapté, un modèle construit à partir de la somme de plusieurs modèles de différentes tailles. Ce procédé est testé sur une image contenant deux régions déterministes (figure 4.11(a), décrite dans le paragraphe 4.3.3.2). Ainsi, si un modèle  $25 \times 25$  est choisi sur l'image des kurtosis obtenue avec une fenêtre  $15 \times 15$  (figure 4.16(a)), seule la région la plus grande est correctement focalisée (figure 4.16(b)). Pour résoudre ce problème, un nouveau modèle est construit en faisant la somme de plusieurs modèles simples, en pondérant chacun par une gaussienne. Pour celle-ci, nous prenons une taille moyenne de  $23 \times 23$  et une incertitude (écart-type de la gaussienne) de 3 (figure 4.17). Nous obtenons alors une assez bonne détection des deux régions avec les valeurs maximales proches des centres des deux régions (figure 4.16(c)). Notons cependant que, dans ce cas, la valeur

maximale de l'image filtrée est bien inférieure à 1. En effet, chaque modèle simple est pondéré par un poids inférieur à 1, dont la somme est égale à 1. Ainsi si la corrélation est proche de 1 pour une certaine dimension (et donc proche de zéro pour les autres), le résultat diminue sensiblement.

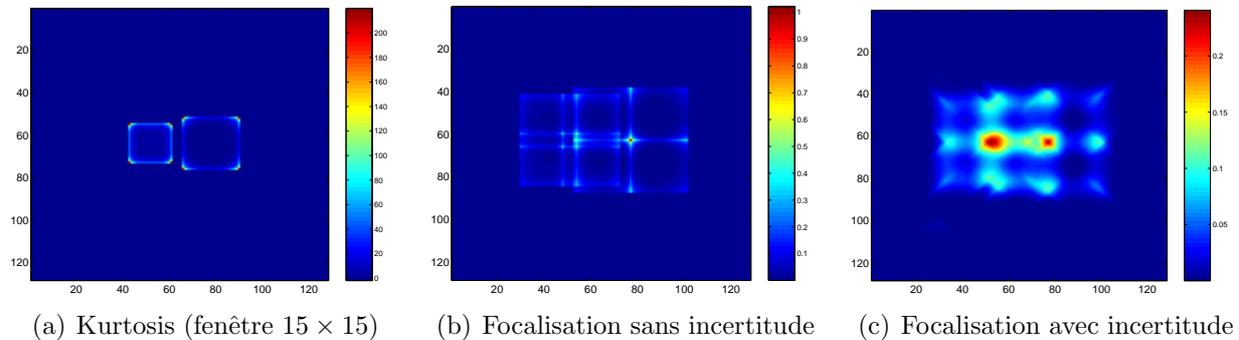


FIG. 4.16 – Focalisation par filtrage adapté sur l'image des kurtosis d'une image contenant deux régions déterministes, en ne tenant pas compte de l'incertitude ( $25 \times 25$ ), et en tenant compte de l'incertitude ( $23 \times 23$ , écart-type = 3).

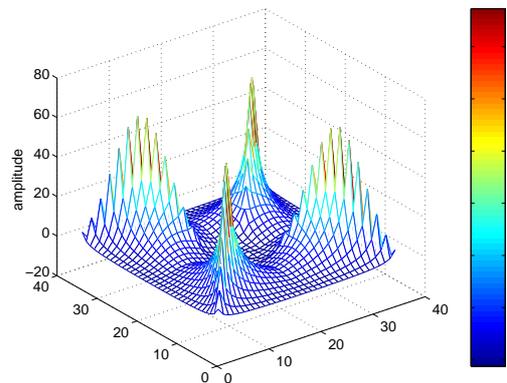


FIG. 4.17 – Modèle théorique du kurtosis utilisé pour le filtre adapté (fenêtre de taille moyenne  $23 \times 23$ , écart-type = 3).

### 4.3.5.3 Reconstruction des régions d'intérêt

Des méthodes de corrélation nous ont permis de focaliser les résultats, c'est-à-dire de ramener les valeurs élevées, qui étaient sur une structure carrée autour de la région recherchée, vers le centre de cette région. Nous obtenons alors un seul point d'amplitude très élevée à l'endroit du centre de la région. Ceci est très intéressant pour détecter et localiser les objets, mais il paraît assez difficile de retrouver la forme et la taille de la région recherchée.

Pour résoudre ce problème, nous proposons de réaliser une dilatation. En effet, connaissant la taille approximative des objets recherchés et l'incertitude que l'on a sur celle-ci, qui nous ont servi lors de la focalisation, nous pouvons "reconstruire" l'objet à partir du centre détecté par les SOS. Pour cela, nous utilisons les ensembles flous [Blo95] permettant de tenir compte de l'incertitude dans la taille de la région recherchée.

La définition de la dilatation en  $x$  appliquée sur l'image  $I$  ( $I(x)$  est la valeur de  $I$  en  $x$ ), avec un élément structurant binaire  $B$  est donnée par :

$$\mathcal{D}_B(x) = \sup_{y \in I} \{I(y) \cdot \delta_{\bar{B}_x}(y)\} \quad (4.36)$$

avec  $\delta_B$ , symbole de Kronecker, une fonction égale à un à l'intérieur de l'élément structurant et à zéro ailleurs.

Maintenant, utilisons un élément structurant flou. A cet élément, nous associons une fonction d'appartenance  $b$  qui à chaque point  $x$  associe une valeur  $b(x) \in [0, 1]$  donnant la probabilité d'appartenance de ce point à l'élément en question. Par la suite, nous confondrons l'élément structurant avec sa fonction d'appartenance. La définition de la dilatation devient :

$$\mathcal{D}_B(x) = \sup_{y \in I} \{I(y) \cdot \bar{b}_x(y)\} \quad (4.37)$$

avec  $\bar{b}_x$  la fonction d'appartenance du symétrique de  $B$  translatée de  $x$ .

Appliquons maintenant cette dernière définition à notre problème de reconstruction d'objet. Comme nous l'avons suggéré précédemment, nous allons utiliser l'aspect flou des éléments structurants pour modéliser l'incertitude sur la taille des régions recherchées. Nous prenons donc un carré dont les dimensions sont "floues", selon une gaussienne avec une moyenne et un écart-type liés à l'incertitude. Ces paramètres ont les mêmes valeurs que celles qui ont été utilisées pour la construction du modèle théorique pour la focalisation. La figure 4.19 montre un exemple d'élément structurant que l'on utilise pour la dilatation appliquée sur l'image des kurtosis (figure 4.18(b)). Le résultat (figure 4.18(c)) montre une bonne reconstruction de la région recherchée, similaire à celle de l'image originale (figure 4.18(a)). Cependant, la dilatation agit sur les artefacts (croix) et a donc tendance à les élargir.

Notons que ces deux étapes de détection (focalisation et reconstruction) ont ici été appliquées dans le cas d'un RSB élevé. Nous pourrions alors penser que ces étapes sont facultatives, un simple seuillage appliqué sur l'image d'origine pouvant faire l'affaire. Mais il faut remarquer que les structures rectangulaires apparaissent également sur les images des SOS pour des RSB plus faibles (à partir de 10dB environ). Les deux étapes décrites peuvent alors tout à fait être appliquées, avec, bien sûr, des valeurs plus faibles pour la corrélation, le résultat s'éloignant du résultat théorique obtenu avec un RSB élevé. Mais ceci reste intéressant, la corrélation avec le fond bruité étant quasiment nulle.

Remarquons, enfin, que ces étapes sont également applicables avec le skewness, en les adaptant, bien entendu, à ses spécificités.

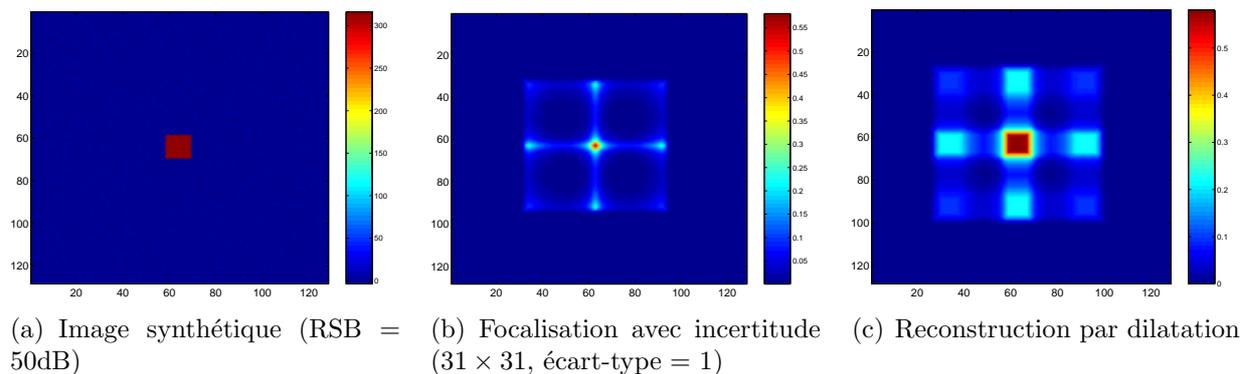


FIG. 4.18 – Reconstruction de la région déterministe, à partir de l'image des kurtosis, par dilatation.

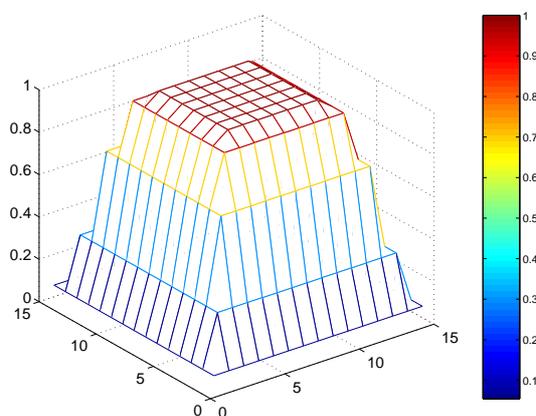


FIG. 4.19 – Élément structurant de la dilatation utilisée pour la reconstruction de la région déterministe ( $11 \times 11$ , écart-type = 1).

## 4.4 Utilisation des statistiques d'ordres supérieurs pour la détection : application aux images sonar

Les outils de détection présentés ci-dessus, utilisant les statistiques d'ordres supérieurs, ont été appliqués à des images synthétiques présentant des cas simples : le fond bruité était gaussien, et les régions d'intérêt étaient suffisamment visibles à l'œil nu pour que ce processus de détection paraisse superflu. Mais ils prennent toute leur place et montrent leur intérêt dans l'application à des données réelles, où des régions de petite taille et de formes plus complexes sont noyées dans un ensemble bruité. C'est notamment le cas des images sonar que nous étudions tout au long de ce mémoire.

### 4.4.1 Spécificités des images sonar

Nous avons vu dans le chapitre 3 que nous pouvions avoir un modèle statistique des images sonar en considérant les échos comme des régions déterministes entourées par un fond bruité. Dans les paragraphes précédents de ce chapitre, nous avons choisi un bruit gaussien pour le fond. Ce choix était dû aux propriétés intéressantes vis à vis des SOS de la distribution gaussienne (nullité du skewness et du kurtosis), ce qui simplifiait largement la compréhension du processus de détection proposé. En ce qui concerne les images sonar, nous avons vu dans le chapitre précédent l'efficacité de la modélisation du fond par la loi de Weibull. C'est cette loi que nous allons donc utiliser ici.

Rappelons la densité de probabilité de cette loi (équation 2.9) :

$$\mathcal{W}_B(B) = \frac{\delta}{\beta} \left( \frac{A}{\beta} \right)^{\delta-1} \exp \left\{ - \left( \frac{B}{\beta} \right)^\delta \right\}; B \geq 0 \quad (4.38)$$

$\beta$  et  $\delta$  étant les deux paramètres de la loi qui peuvent être estimés par maximum de vraisemblance (chapitre 2). Définissons maintenant la grandeur  $\gamma_k$  comme :

$$\gamma_k = \Gamma \left( 1 + \frac{k}{\delta} \right) \quad (4.39)$$

avec  $\Gamma$  la fonction Gamma. Nous en déduisons les moments décentrés d'ordre  $r$  (équation 2.10) :

$$\mu'_{B(r)} = \beta^r \gamma_r \quad (4.40)$$

et les cumulants aux ordres 2, 3 et 4 du fond bruité (équation 4.6) :

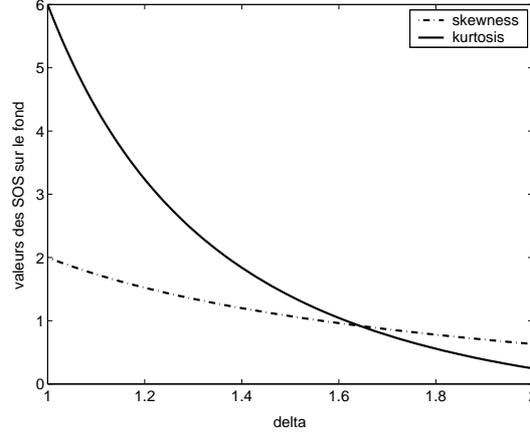
$$\begin{aligned} \kappa_{B(2)} &= \beta^2(\gamma_2 - \gamma_1^2) \\ \kappa_{B(3)} &= \beta^3(\gamma_3 - 3\gamma_1\gamma_2 + 2\gamma_1^3) \\ \kappa_{B(4)} &= \beta^4(\gamma_4 - 4\gamma_3\gamma_1 - 3\gamma_2^2 + 12\gamma_2\gamma_1^2 - 6\gamma_1^4) \end{aligned} \quad (4.41)$$

Nous en déduisons les valeurs du skewness et du kurtosis pour le fond bruité :

$$\mathcal{S}_B = \frac{\gamma_3 - 3\gamma_2\gamma_1 + 2\gamma_1^3}{(\gamma_2 - \gamma_1^2)^{3/2}} \quad (4.42)$$

$$\mathcal{K}_B = \frac{\gamma_4 - 4\gamma_3\gamma_1 - 3\gamma_2^2 + 12\gamma_2\gamma_1^2 - 6\gamma_1^4}{(\gamma_2 - \gamma_1^2)^2} \quad (4.43)$$

Nous pouvons donc constater que les skewness et kurtosis ne sont plus nuls pour le fond bruité dans le cas des images sonar. La figure 4.20 nous montre la variation des valeurs de ces grandeurs en fonction du paramètre  $\delta$  de la loi de Weibull. Sur les images SAS, le paramètre  $\delta$  est fortement lié à la résolution, mais se situe généralement entre les valeurs 1,60 et 1,70 (voir les estimations du chapitre 2). Ces valeurs correspondent à des valeurs entre 0,8 et 1,0 environ pour le skewness et le kurtosis (voir sur la figure 4.20).


 FIG. 4.20 – Valeurs des SOS sur un fond bruité (Weibull) en fonction du paramètre  $\delta$ .

#### 4.4.1.1 Conséquences sur la détection

Du fait de la non gaussianité du fond bruité, quelques changements interviennent dans les valeurs de skewness et kurtosis au niveau local sur les images sonar. Ainsi, les valeurs des moments décentrés sur la fenêtre de calcul deviennent (comparer avec l'équation 4.27) :

$$\begin{aligned}
 \mu'_{F(1)} &= pD + (1-p)\beta\gamma_1 \\
 \mu'_{F(2)} &= pD^2 + (1-p)\beta^2\gamma_2 \\
 \mu'_{F(3)} &= pD^3 + (1-p)\beta^3\gamma_3 \\
 \mu'_{F(4)} &= pD^4 + (1-p)\beta^4\gamma_4
 \end{aligned} \tag{4.44}$$

Nous pouvons donc constater qu'ici les moments décentrés d'ordres impairs (1 et 3) dépendent des paramètres statistiques du fond. Nous en déduisons les valeurs des cumulants :

$$\begin{aligned}
 \kappa_{F(2)} &= (1-p)\{pD^2 - 2\gamma_1 p D \beta + (\gamma_2 - \gamma_1^2 + \gamma_1^2 p)\beta^2\} \\
 \kappa_{F(3)} &= (1-p)\{p(1-2p)D^3 - 3p(1-2p)\gamma_1 D^2 \beta - 3p(\gamma_2 - 2\gamma_1^2 + 2\gamma_1^2 p)D\beta^2 + \dots \\
 &\quad + [\gamma_3 - 3\gamma_2\gamma_1 + 2\gamma_1^3 + \gamma_1(3\gamma_2 - 4\gamma_1^2)p + 2\gamma_1^3 p^2]\beta^3\} \\
 \kappa_{F(4)} &= (1-p)\{p(1-6p+6p^2)D^4 - 4p(1-6p+6p^2)\gamma_1 D^3 \beta - \dots \\
 &\quad - 6p[\gamma_2 - 2\gamma_1^2 - 2(\gamma_2 - 4\gamma_1^2)p - 6\gamma_1^2 p^2]D^2 \beta^2 - \dots \\
 &\quad - 4p[\gamma_3 - 6\gamma_2\gamma_1 + 6\gamma_1^3 + 6\gamma_1(\gamma_2 - 2\gamma_1^2)p + 6\gamma_1^3 p^2]D\beta^3 + \dots \\
 &\quad + [\gamma_4 - 3\gamma_2^2 - 4\gamma_3\gamma_1 + 12\gamma_2\gamma_1^2 - 6\gamma_1^4 + (3\gamma_2^2 + 4\gamma_3\gamma_1 - 24\gamma_2\gamma_1^2 + 24\gamma_1^4)p + \dots \\
 &\quad + 12\gamma_1^2(\gamma_2 - 3\gamma_1^2)p^2 + 24\gamma_1^4 p^3 - 6\gamma_1^4 p^4]\beta^4\}
 \end{aligned} \tag{4.45}$$

De ces expressions assez complexes, nous pouvons déjà tirer une première remarque : le comportement des SOS pour les RSB élevés n'est pas modifié par rapport au cas gaussien (les termes en  $D^r$  pour les cumulants d'ordre  $r$  sont identiques dans les équations 4.45 et 4.28). Ceci est déjà très intéressant : les propriétés et les processus de détection (focalisation et reconstruction) présentés dans le cas gaussien pour des RSB élevés restent encore valables

dans le cas des images sonar. Notons également que nous retrouvons les expressions des équations 4.42 et 4.43 en faisant tendre  $D$  et  $p$  vers zéro (fond bruité).

Les figures 4.21, 4.22 et 4.23 nous montrent le comportement des SOS dans le cas des images sonar (fond modélisé par une loi de Weibull avec  $\delta = 1,65$ ). Ici, le RSB a été défini par la relation :

$$\rho_w = \frac{D}{\beta} \quad (4.46)$$

En effet, dans le cas de la loi de Weibull, le paramètre lié à l'intensité du bruit (l'équivalent de l'écart-type  $\sigma_B$  pour la loi gaussienne) est le paramètre d'échelle  $\beta$ .

Nous constatons alors des similitudes entre les comportements des SOS dans le cas des images sonar et ceux dans le cas gaussien (voir la paragraphe 4.3.1.2). Ainsi, les comportements des skewness et des kurtosis dans le cas d'un RSB élevé sont identiques dans les deux cas (figure 4.23(b)). De même, pour des valeurs de  $p$  faibles, les comportements sont identiques, avec des valeurs proches des valeurs du fond (proches de 1) pour de faibles RSB, une augmentation à partir de 10dB et une stabilisation après environ 40dB à des valeurs proches de  $1/\sqrt{p}$  pour le skewness et de  $1/p$  pour le kurtosis.

Quelques différences interviennent dans le cas du skewness pour de faibles RSB : le skewness  $a$ , dans le cas du modèle de Weibull, une valeur non nulle, et différente de celle du fond, pour des valeurs élevées du paramètre  $p$ . En effet, contrairement au cas gaussien (voir la figure 4.3), la distribution de Weibull est décentrée. L'ajout de pixels déterministes, avec un RSB faible (proche de zéro), renforce alors ce décentrage, d'où un skewness plus élevé. Le skewness pourrait alors nous servir pour la détection ici.

Notons également la présence de pics pour le skewness et le kurtosis au niveau d'un RSB de 0dB pour des valeurs de  $p$  élevées (figure 4.22). Ceci correspond donc au cas où  $D = \beta$ , c'est-à-dire quand les pixels déterministes ont leur valeur à l'endroit précis où la densité de probabilité de la loi de Weibull est à son maximum. L'ajout de pixels déterministes accentue alors la dissymétrie de la distribution (skewness élevé), et surtout son étirement vertical, d'où un kurtosis élevé.

Pour conclure, nous pouvons dire que les propriétés des statistiques d'ordres supérieurs, et les méthodes de détections en découlant, peuvent parfaitement, à quelques détails près, être transposées au cas du fond modélisé par une loi de Weibull. Elles peuvent donc être appliquées au cas des images sonar. Le paragraphe suivant présente les résultats obtenus sur ces images.

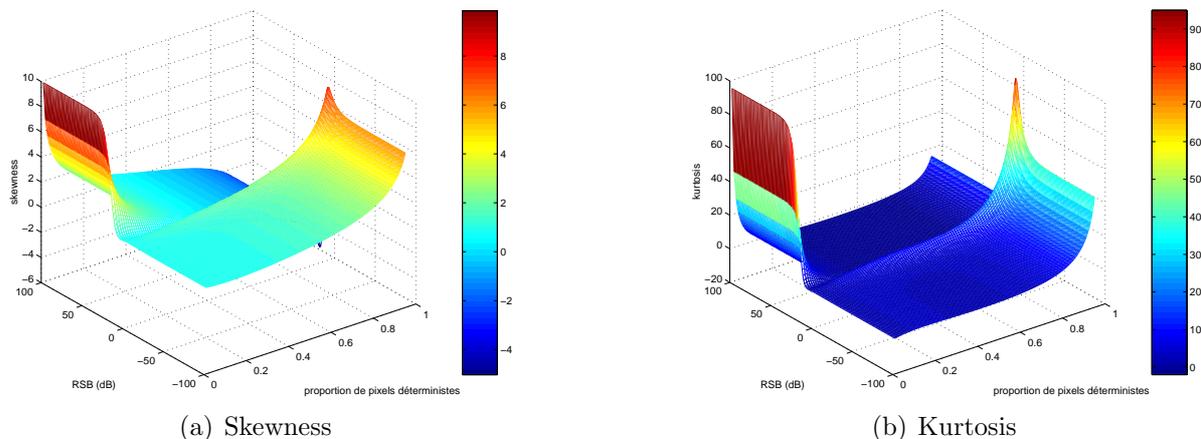


FIG. 4.21 – Valeurs des skewness et kurtosis en fonction de la proportion de pixels déterministes  $p$  et du RSB ( $\delta = 1, 65$ ).

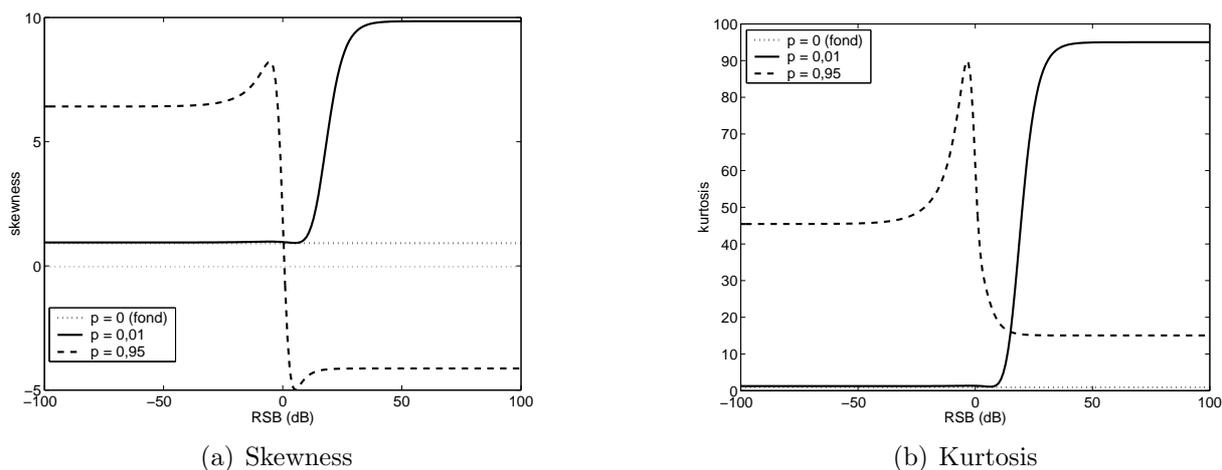


FIG. 4.22 – Valeurs des skewness et kurtosis en fonction du RSB pour des valeurs de  $p$  faibles (trait continu) ou élevées (traits pointillés) ( $\delta = 1, 65$ ).

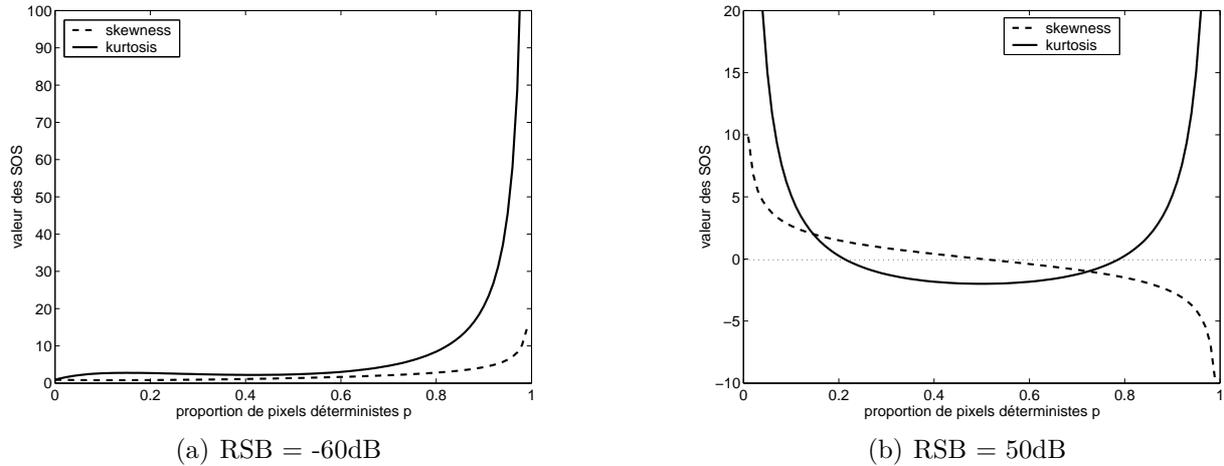


FIG. 4.23 – Valeurs des skewness (traits pointillés) et kurtosis (trait continu) en fonction du paramètre  $p$  pour des RSB faibles et élevés ( $\delta = 1, 65$ ).

## 4.4.2 Résultats et évaluation

### 4.4.2.1 Résultats sur les données SAS

Dans cette partie, les méthodes de détection proposées dans ce chapitre seront testées sur des images SAS présentées dans le chapitre 1. Notons tout d'abord que les RSB se situent dans notre cas généralement au delà de 10dB, les échos ayant une amplitude moyenne supérieure à trois fois la valeur du paramètre  $\beta$  de la loi de Weibull, même si de nombreux pixels du fond peuvent avoir des valeurs supérieures. L'objectif sera de séparer efficacement ces pixels, plutôt isolés, des échos. Nous nous situons alors dans le cas d'un RSB élevé ou intermédiaire, avec l'apparition de structures rectangulaires autour des échos. Les processus de détection liés à cette situation (focalisation et dilatation) sont alors appliqués (figures 4.24(a) à 4.41).

Nous choisissons alors une fenêtre de calcul des skewness et kurtosis largement supérieure à la taille des échos et inférieure à l'espace minimum entre les objets. La forme de la fenêtre est carrée.

Nous pouvons alors voir, de façon qualitative, que les SOS permettent de bien mettre en évidence les échos présents sur les images (après focalisation et reconstruction par dilatation), y compris dans le cas d'objets enfouis. On peut également constater que les images des kurtosis présentent un meilleur contraste que celles obtenues avec le skewness. En effet, comme nous pouvons le voir sur la figure 4.22, pour les RSB entre 10dB et 40dB, les valeurs du skewness croissent entre une valeur proche de 1 et  $1/\sqrt{p}$ , soit moins brutalement que pour le kurtosis (entre 1 et  $1/p$ ). Remarquons également les valeurs proches de 1 (valeur approchée théorique des SOS pour une loi de Weibull dans le cas des images SAS) sur les images des SOS dans les régions correspondant au fond bruité. Ceci est surtout visible sur les images des skewness (figures 4.28, 4.33(a), 4.37(a) et 4.41(a)), la dynamique des images des kurtosis ne permettant pas de bien distinguer les valeurs proches de 1 de celles proches

de zéro.

Notons toutefois que l'on a présenté séparément la partie gauche de l'image C, la mine de droite, posée sur le fond, prenant toute la dynamique. En effet, son RSB est beaucoup plus élevé que celui des autres objets et ses SOS se situent alors vers le haut des pentes de la figure 4.22 (pour un  $p$  faible). On peut remarquer que les valeurs des SOS sont très proches les unes des autres pour les objets de la partie gauche de l'image (figure 4.27(b)). En ce qui concerne le skewness, l'écart entre les valeurs correspondant à l'objet de droite et celles de la partie gauche est beaucoup moins important (voir la remarque du paragraphe précédent).

Nous pouvons également constater que l'application des méthodes de détection sur l'image B (figure 4.39) ne donne pas des résultats très satisfaisants (figures 4.40 et 4.41). En effet, la mine sphérique semble assez bien détectée. Par contre, la mine cylindrique l'est beaucoup moins bien, avec des valeurs plus faibles. Ceci vient du fait que l'écho est très grand, et ne peut donc pas être contenu dans la fenêtre de calcul. Le choix d'une fenêtre plus grande aurait de toute façon été impossible, l'espace entre les deux objets étant plus petit que la taille de la mine cylindrique. Un autre problème lié à cette mine est son orientation non verticale. Le choix d'une fenêtre orientée selon l'angle formé par l'objet aurait donné sûrement de meilleurs résultats. Sur cette même image, nous pouvons également remarquer des valeurs des SOS plus faibles que pour le fond, et très proches de zéro, au niveau des ombres. Ceci tend à confirmer la gaussianité de ces régions (voir le chapitre 2).

#### 4.4.2.2 Evaluation quantitative des performances de détection

Dans ce paragraphe, nous allons étudier quantitativement la méthode de détection basée sur les SOS sur les images SAS, au moyen de courbes COR, avec les mêmes définitions que dans le chapitre 3 (paragraphe 3.5.1). Les courbes COR associées aux SOS sont construites en réalisant un seuillage progressif des résultats obtenus avec le skewness et le kurtosis sur les images SAS, après focalisation et reconstruction (environ 50 réalisations pour chacune).

Les figures 4.30, 4.34, 4.38 et 4.42 représentent les courbes COR obtenues sur les images SAS avec les méthodes de détection basées sur le skewness et le kurtosis, comparées à celle obtenue avec un simple seuillage. Nous pouvons ainsi constater que les méthodes utilisant le skewness et le kurtosis sont plus performantes qu'un simple seuillage, la probabilité de détection associée à celui-ci étant inférieure à celle des SOS pour un taux de fausse alarme donné, et la probabilité de détection atteignant 1 plus rapidement par les SOS.

Notons également que le skewness semble, paradoxalement au vu des remarques faites précédemment sur les contrastes, plus performant que le kurtosis (excepté pour l'image E pour laquelle les courbes associées à chacun des SOS se croisent à deux reprises). Ceci vient de la variance de l'estimateur du kurtosis qui est plus importante que celle du skewness, d'où un taux de fausse alarme plus élevé pour une probabilité de détection donnée.

## 4.5 Conclusion sur l'utilisation des statistiques d'ordres supérieurs

Dans ce chapitre, nous avons proposé une méthode de détection basée sur les statistiques d'ordres supérieurs, et en particulier sur les ordres 3 (skewness) et 4 (kurtosis). L'évaluation locale de ces grandeurs permet de mettre en évidence les échos, puis, après focalisation par filtrage adapté et reconstruction par dilatation, de les détecter et les différencier du fond (valeurs faibles). De bons résultats sont obtenus, y compris dans le cas d'objets enfouis, avec un rapport signal à bruit plus faible.

L'intérêt de cette méthode et sa validation par l'évaluation de ses performances ont été soulignés par les courbes COR. Le skewness et le kurtosis sont ainsi beaucoup plus performants qu'un simple seuillage, et le skewness semble plus intéressant que le kurtosis, malgré le moins bon contraste des résultats.

Les statistiques d'ordres supérieurs constituent ainsi une prolongation de la méthode de détection, basée sur les deux premiers ordres, présentée dans le chapitre précédent. Ceci constitue un complément d'information intéressant sur l'image et pour la détection des objets recherchés. En effet, elles permettent une bonne localisation et détection des objets, mais ne donne pas beaucoup d'information sur la forme de ces régions. Par contre, les statistiques des deux premiers ordres fournissaient une information précise sur la forme des échos, mais présentaient de nombreuses fausses alarmes. Les performances de ces détecteurs seront comparées dans le chapitre 5 dans lequel sera proposée leur utilisation conjointe au moyen d'un processus de fusion.

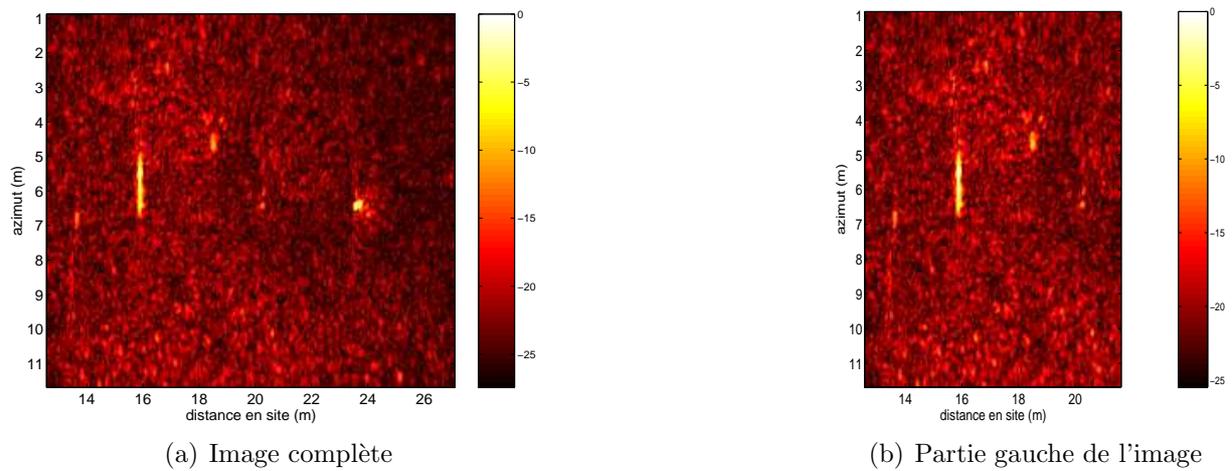
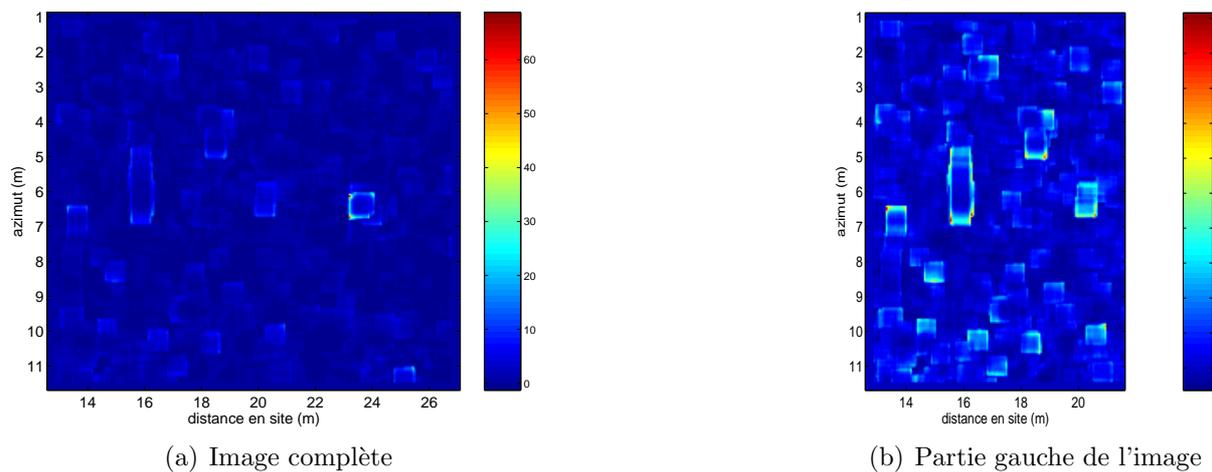


FIG. 4.24 – Image C et partie gauche de l'image.

FIG. 4.25 – Images des kurtosis sur l'image C (fenêtre  $11 \times 11$ ).

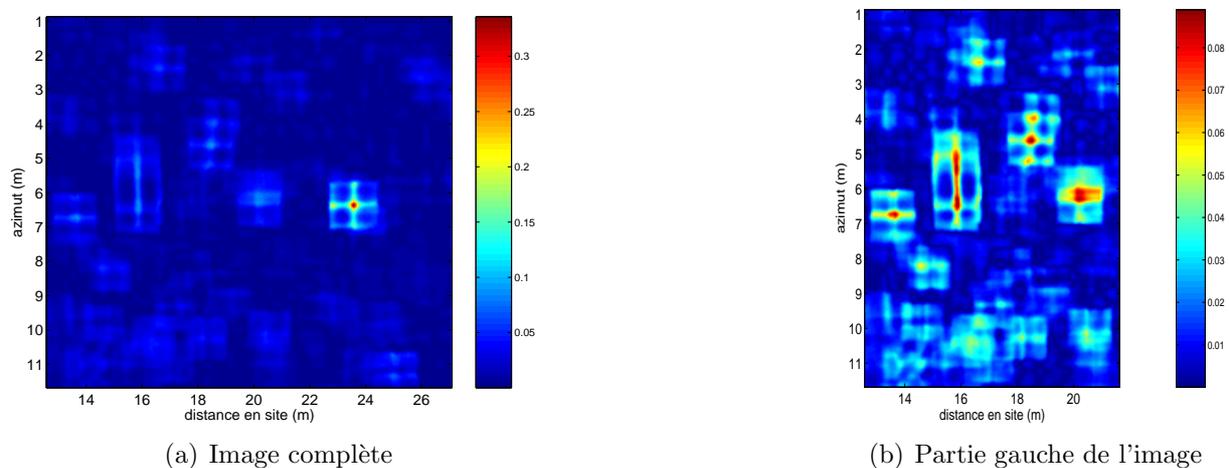


FIG. 4.26 – Focalisation des kurtosis sur l'image C (taille estimée des objets : moyenne =  $5 \times 5$ , écart-type = 1).

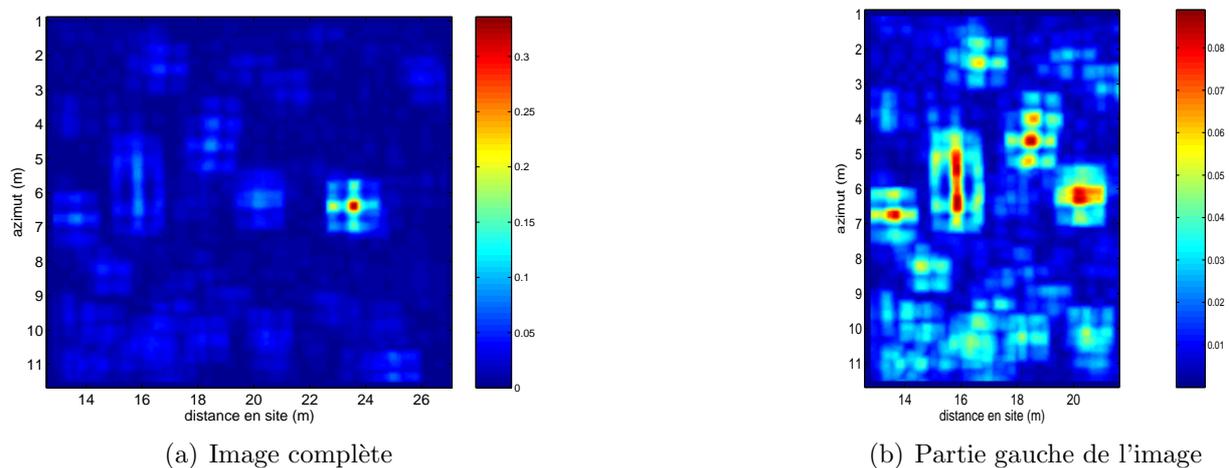
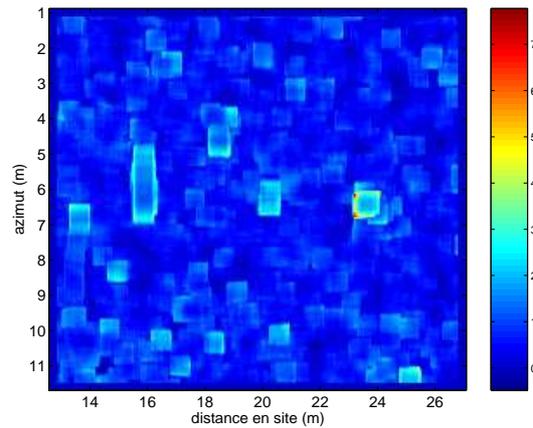
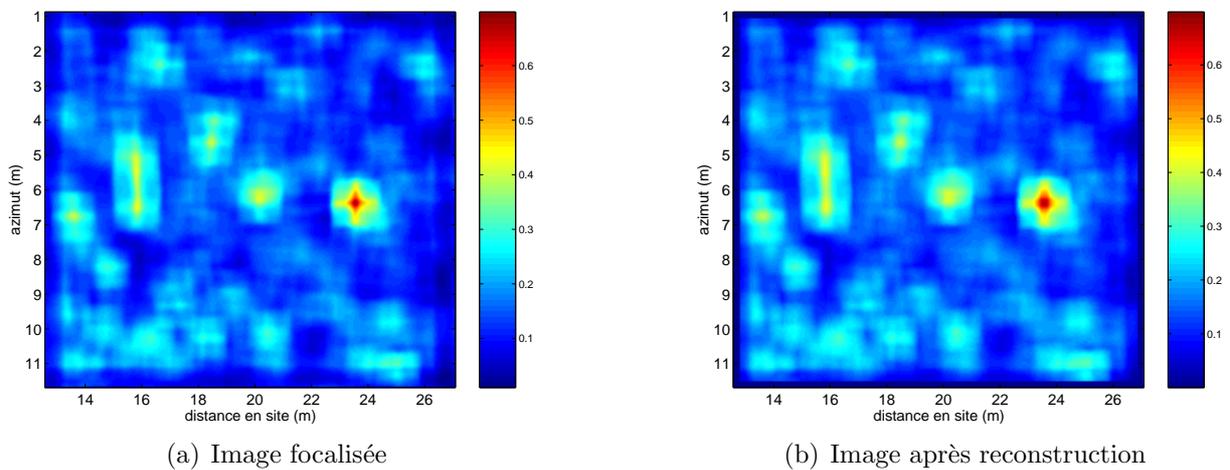


FIG. 4.27 – Reconstruction des objets à partir du kurtosis sur l'image C (paragraphe 4.3.5.3).

FIG. 4.28 – Image des skewness sur l'image C (fenêtre  $11 \times 11$ ).

(a) Image focalisée

(b) Image après reconstruction

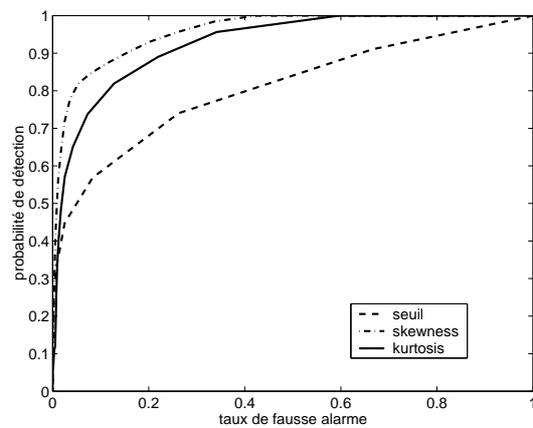
FIG. 4.29 – Images des skewness de l'image C après focalisation et reconstruction (taille estimée des objets : moyenne =  $5 \times 5$ , écart-type = 1).

FIG. 4.30 – Performances des SOS sur l'image C comparées avec un simple seuillage.

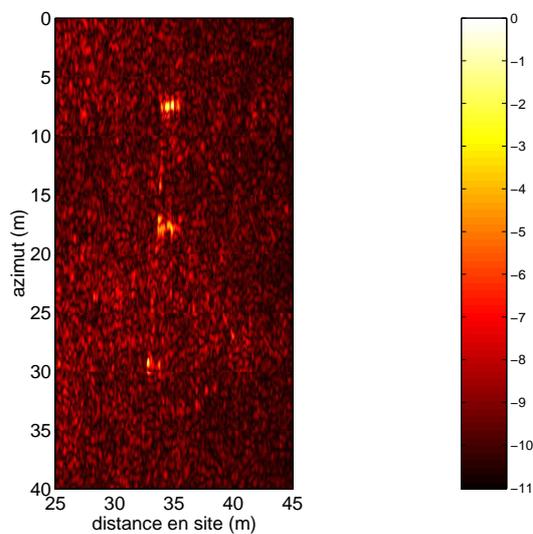
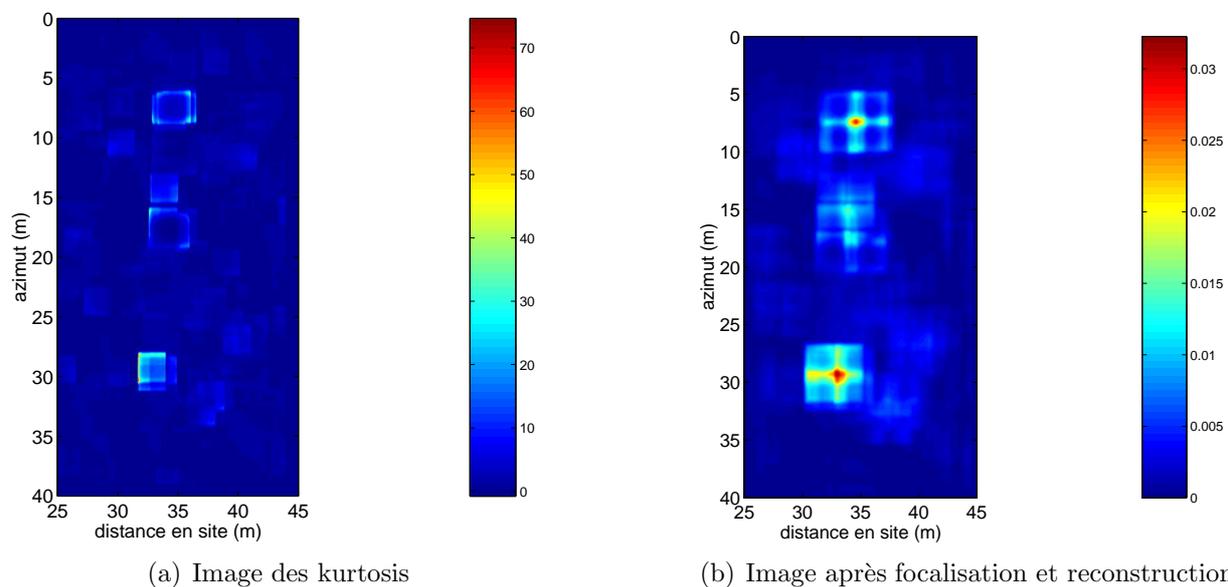


FIG. 4.31 – Image D.



(a) Image des kurtosis

(b) Image après focalisation et reconstruction

FIG. 4.32 – Images des kurtosis de l'image D, focalisation et reconstruction (fenêtre  $55 \times 55$ , taille estimée des objets : moyenne =  $11 \times 11$ , écart-type = 3).

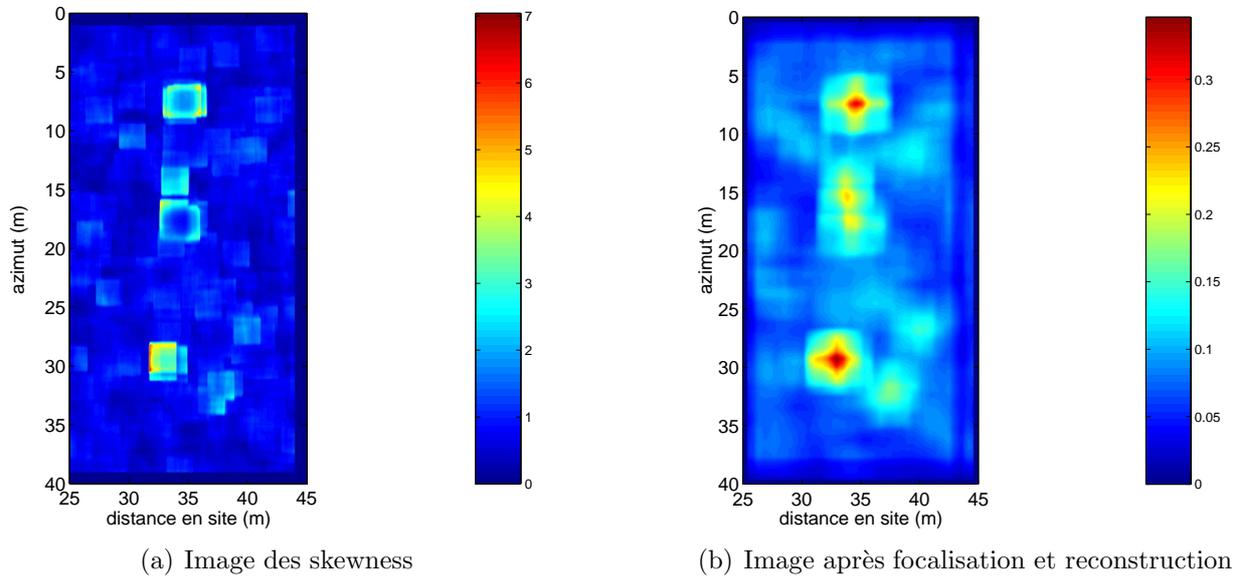


FIG. 4.33 – Images des skewness de l'image D, focalisation et reconstruction (fenêtre  $55 \times 55$ , taille estimée des objets : moyenne =  $11 \times 11$ , écart-type = 3).

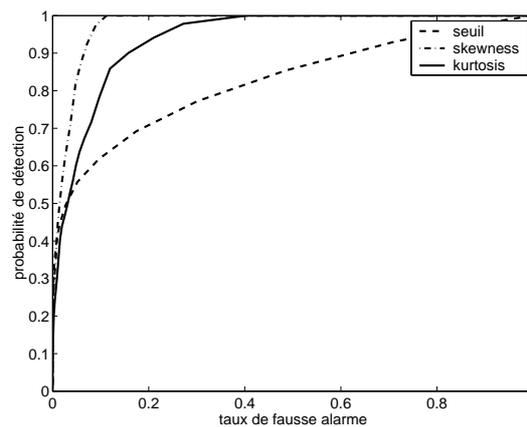


FIG. 4.34 – Performances des SOS sur l'image D comparées avec un simple seuillage.

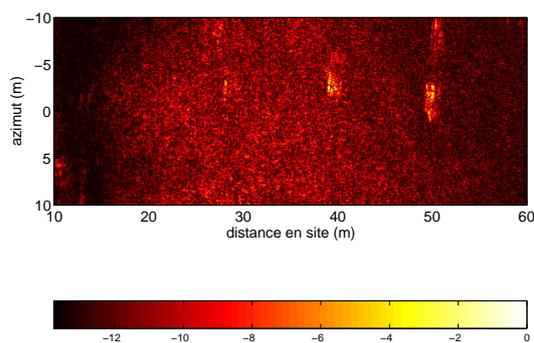
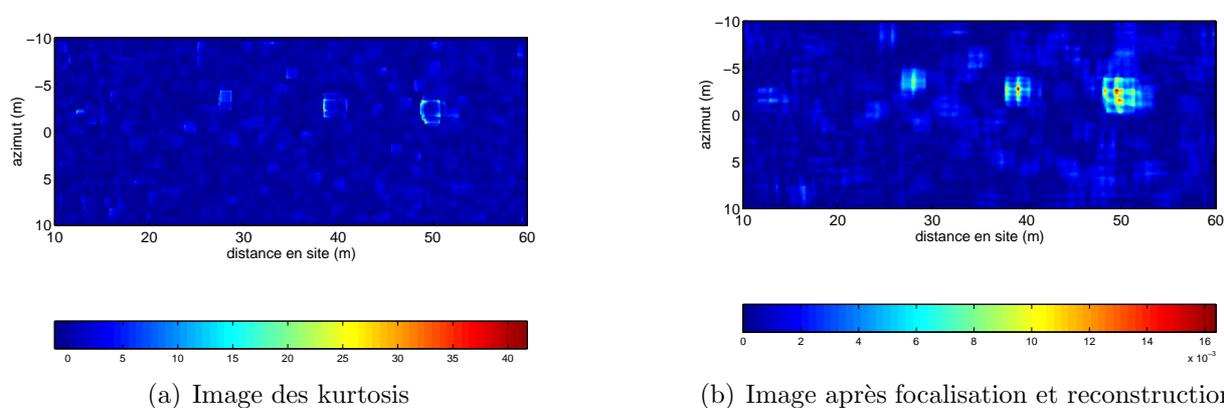
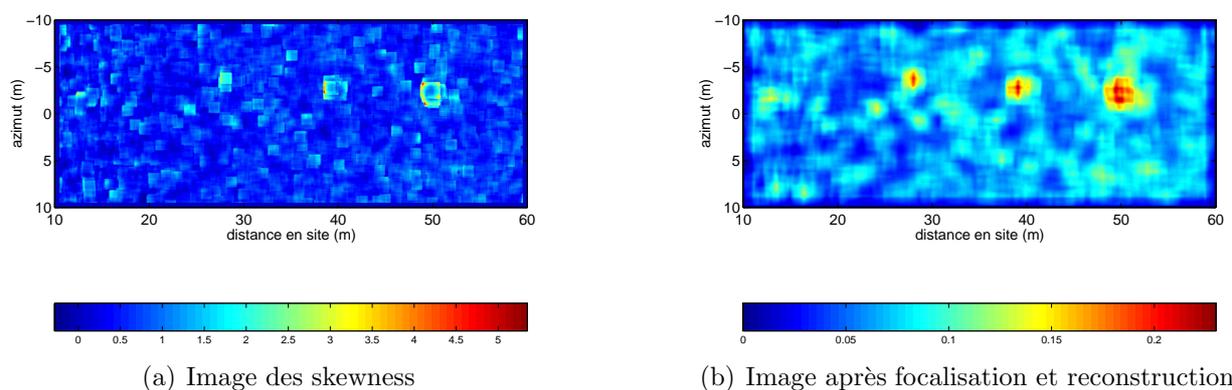


FIG. 4.35 – Image E.

FIG. 4.36 – Images des kurtosis de l'image E, focalisation et reconstruction (fenêtre  $55 \times 55$ , taille estimée des objets : moyenne =  $11 \times 11$ , écart-type = 3).FIG. 4.37 – Images des skewness de l'image E, focalisation et reconstruction (fenêtre  $55 \times 55$ , taille estimée des objets : moyenne =  $11 \times 11$ , écart-type = 3).

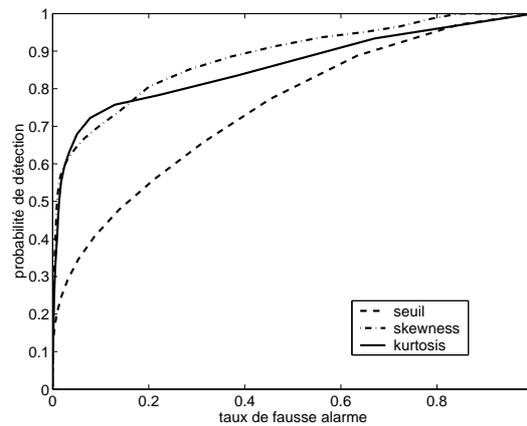


FIG. 4.38 – Performances des SOS sur l'image E comparées avec un simple seuillage.

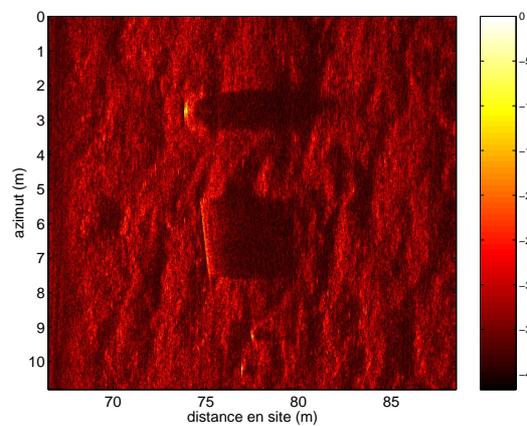
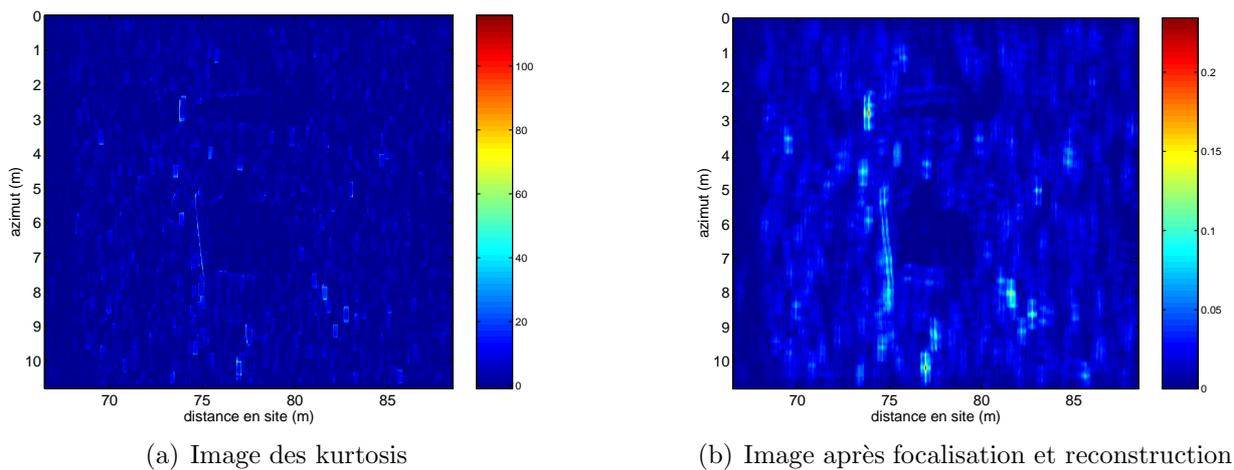


FIG. 4.39 – Image B.

FIG. 4.40 – Images des kurtosis de l'image B, focalisation et reconstruction (fenêtre  $21 \times 21$ , taille estimée des objets : moyenne =  $5 \times 5$ , écart-type = 1).

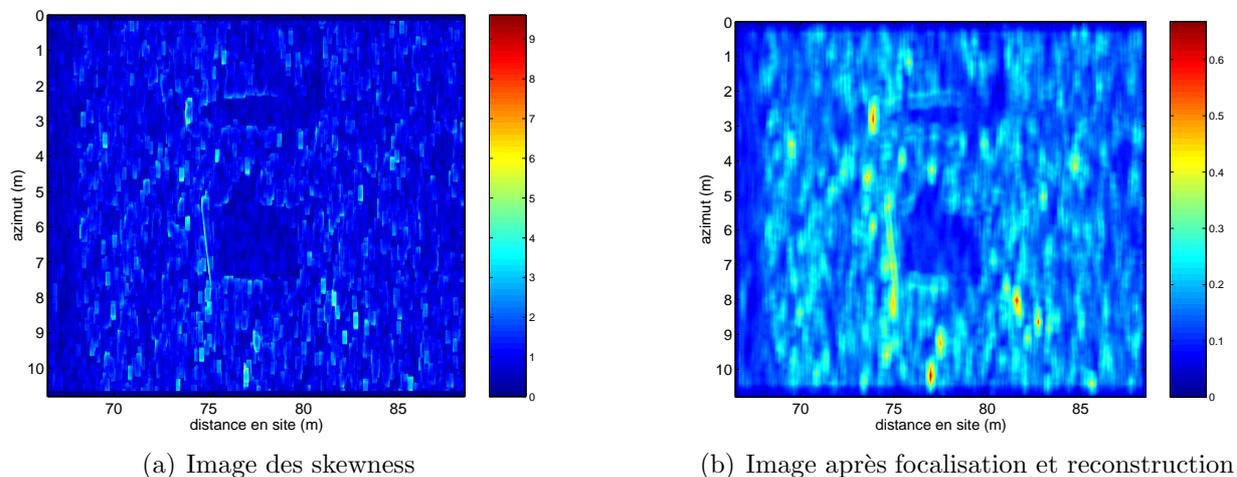


FIG. 4.41 – Images des skewness de l'image B, focalisation et reconstruction (fenêtre  $21 \times 21$ , taille estimée des objets : moyenne =  $5 \times 5$ , écart-type = 1).

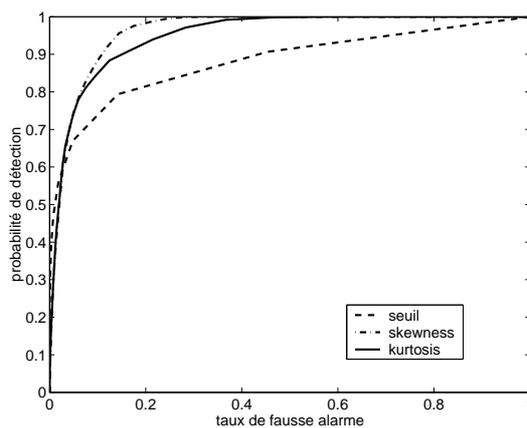


FIG. 4.42 – Performances des SOS sur l'image B comparées avec un simple seuillage.

# Chapitre 5

## Fusion des données

Les différents paramètres extraits des images sonar et les résultats obtenus en terme de détection sont fusionnés afin d'avoir une classification de chaque pixel de l'image selon qu'il est susceptible d'appartenir à un écho ou pas.

Les paramètres étant de natures et d'ordres de grandeur différents, un processus de combinaison adapté à notre problème est nécessaire pour réaliser cette fusion. Pour ceci, notre choix s'est porté sur la théorie de l'évidence, en s'inspirant des ensembles flous pour définir les masses d'évidence.

Les résultats ainsi obtenus peuvent alors être évalués numériquement par des grandeurs spécifiques, telles que la non-spécificité, ou déjà utilisées précédemment, telles que la probabilité de détection et le taux de fausse alarme. L'intérêt de l'apport de chaque paramètre, pris séparément ou ensemble, peut également être estimé par ces grandeurs.

La prise de décision peut alors se faire au regard de différents résultats issus de la fusion tels que la croyance ou la plausibilité.

---

## Sommaire

---

<b>5.1</b>	<b>Introduction</b>	<b>123</b>
<b>5.2</b>	<b>Choix de la méthode de fusion</b>	<b>123</b>
5.2.1	Intérêt de la fusion de données	123
5.2.1.1	Définition de la fusion	123
5.2.1.2	Termes de la fusion : description de l'information	124
5.2.1.3	Sources d'information et objectifs de la fusion en traitement d'images	125
5.2.2	Différentes méthodes de fusion et choix de la méthode	126
5.2.2.1	Etat de l'art des processus de fusion pour la détection d'objets	126
5.2.2.2	Choix de la méthode de fusion	126
5.2.3	Théorie de l'évidence	127
5.2.3.1	Principe de la théorie	127
5.2.3.2	Modélisation	128
5.2.3.3	Combinaison	129
<b>5.3</b>	<b>Application à la détection en imagerie sonar</b>	<b>130</b>
5.3.1	Choix des paramètres et schéma de la fusion	130
5.3.1.1	Paramètres fusionnés	130
5.3.1.2	Schéma de la fusion	131
5.3.2	Choix des hypothèses et définition des fonctions de masse	132
5.3.2.1	Choix des hypothèses	132
5.3.2.2	Définition des fonctions de masse	132
5.3.2.3	Combinaison	136
5.3.3	Evaluations de la performance de classification	136
5.3.3.1	Evaluation de la performance en absolu	137
5.3.3.2	Evaluation de la performance à partir de la vérité terrain	138
5.3.3.3	Probabilité de détection et taux de fausse alarme	139
<b>5.4</b>	<b>Résultats sur les données sonar</b>	<b>139</b>
5.4.1	Fusion des données sur les images SAS	139
5.4.1.1	Estimation et combinaison	139
5.4.1.2	Evaluation des performances	143
5.4.1.3	Résultats sur d'autres données sonar	147
5.4.2	Représentation des résultats	151
5.4.2.1	Classification	151
5.4.2.2	Transposition des résultats sur l'image originale	151
5.4.3	Utilisation d'autres paramètres	155
<b>5.5</b>	<b>Conclusion</b>	<b>157</b>

---

## 5.1 Introduction

Dans les deux chapitres précédents, nous avons présenté des méthodes de détection des objets avec un certain succès, à partir de paramètres statistiques issus des images sonar. Il serait alors intéressant de pouvoir combiner ces résultats afin d'avoir une détection encore plus performante, et une classification des différentes régions de l'image selon qu'elles sont susceptibles de contenir des objets ou pas. Ceci est l'objectif de ce chapitre.

Ce chapitre se décompose alors en trois parties principales. Nous allons tout d'abord exposer des méthodes de fusion utilisées dans la littérature et leurs applications particulièrement en imagerie sonar, puis exposer les raisons de notre choix de la théorie de l'évidence. Celle-ci fera l'objet d'une présentation détaillée. Nous verrons ensuite comment l'appliquer à notre problème de détection sur les images sonars. Le processus ainsi développé sera testé sur les images SAS, utilisées tout au long de ce mémoire, et évalué à partir de critères numériques. Nous étudierons enfin les moyens de présenter les résultats de la fusion.

## 5.2 Choix de la méthode de fusion

### 5.2.1 Intérêt de la fusion de données

La fusion de données est devenue un aspect important de traitement de l'information dans de nombreux domaines d'application. Face à la multiplication des types de capteurs (les systèmes imageurs par exemple) et des algorithmes d'analyse d'images, il s'est avéré nécessaire de combiner ces différentes données afin d'aider l'utilisateur dans sa prise de décision, sans avoir à étudier un nombre trop important de paramètres. C'est ainsi que les premiers processus de fusion sont apparus dans les années 1960 [Blo96], lors du développement de calculateurs de forte capacité, basés sur les probabilités. Les théories plus récentes (théories des croyances et des possibilités) sont elles apparues dans les années 1970. Leur utilisation en traitement d'images a commencé dans les années 1980 dans l'imagerie satellitaire, et s'est développée plus récemment en imagerie médicale [Blo95].

#### 5.2.1.1 Définition de la fusion

Plusieurs définitions de la fusion de données ont été proposées [Val01] cherchant à être la plus générale possible. Mais il paraît difficile, voire impossible, d'avoir une définition globale, chacune d'entre elles se référant à un domaine d'application. La définition qui me paraît la plus adéquate à notre cas, tout en étant suffisamment générale est celle-ci [Blo03] :

**Définition :** La fusion d'informations consiste à combiner des informations issues de plusieurs sources afin d'améliorer la prise de décision.

Cette définition est issue de discussions menées au sein du groupe de travail sur la fu-

sion d'informations du GDR-PRC ISIS<sup>1</sup>. Elle s'applique parfaitement aux problèmes de traitement du signal et des images tout en étant suffisamment générale, les termes "informations" (numériques ou symboliques) et "sources" (voir les différents types de sources en traitement d'images dans la suite de cette partie) englobant de nombreuses possibilités. De même, la notion d'amélioration dépend fortement de l'application.

Les principales étapes à suivre pour construire un processus de fusion sont [Blo03] :

1. **la modélisation** : cette étape suppose le choix d'un formalisme, et des expressions des informations à fusionner. La forme de la représentation de l'information peut être une distribution de probabilité, une formule logique, . . . ;
2. **l'estimation**, notamment pour les méthodes utilisant des distributions ;
3. **la combinaison** : on choisit ici un opérateur compatible au formalisme choisi lors de la première étape ;
4. **la décision** : étape ultime de la fusion, elle conduit au choix d'une décision à partir des informations fournies.

Des informations supplémentaires (sur le contexte ou le domaine d'application) peuvent intervenir à chacune de ces étapes. D'autres modèles existent : certains proposent de prendre une décision locale au niveau de chaque source séparément, avant qu'elle soit combinée avec les autres. D'autres utilisent une combinaison des représentations des informations relatives à la même décision, ou un modèle hybride (exemple des architectures multiagents [Blo03]).

### 5.2.1.2 Termes de la fusion : description de l'information

Ce qui caractérise avant tout l'information en fusion est son imperfection. En effet, si celle-ci était parfaite, la fusion ne serait pas nécessaire. Elle peut être caractérisée par différents termes [Rom01, Blo03] :

- **l'incertitude** : elle évalue le degré de conformité à la réalité d'une information, en ce qui concerne sa nature, sa qualité, son essence ou son occurrence.
- **l'imprécision** : elle décrit le contenu de l'information et mesure le défaut quantitatif d'information apportée par celui-ci. Elle fait référence au manque d'exactitude en quantité, en taille, en durée, . . . Elle ne doit pas être confondue avec l'incertitude, même si l'un peut conduire à l'autre. Par exemple, l'information "Paul est grand" est certaine (on sait que Paul n'est pas petit, ni moyen), mais n'est pas précise (on ne connaît pas sa taille). Par contre, l'information "Paul mesure 1,80m" est précise, mais n'est pas forcément certaine (il existe une incertitude sur la taille exacte de Paul : peut-être mesure-t-il 1,81m). L'ambivalence exactitude / certitude est au coeur des problèmes de fusion : on perd souvent en exactitude quand on veut être précis, et inversement.
- **l'incomplétude** : elle caractérise l'absence d'information par la source sur certains aspects du problème. Elle est justement la raison principale de la fusion d'informations fournies par plusieurs sources.

---

<sup>1</sup><http://www-isis.enst.fr>

- **l’ambiguïté** : elle fait référence à la capacité pour une information à conduire à plusieurs interprétations. L’objectif de la fusion est alors de lever cette ambiguïté en combinant cette information avec d’autres.
- **le conflit** : il caractérise deux ou plusieurs informations conduisant à des interprétations contradictoires. Celui-ci est assez délicat à manipuler au sein du processus de fusion. Ainsi, certaines méthodes l’ignorent totalement, d’autres en tiennent compte en cherchant à l’éliminer (en éliminant les sources apportant ce conflit, en prenant en compte des informations supplémentaires, ...) ou en le conservant afin d’attirer l’attention de l’opérateur sur sa présence.

L’objectif de la fusion est alors de palier ces imperfections en combinant différentes informations.

D’autres propriétés, plus positives, des informations sont exploitées lors de la fusion :

- **la redondance** : elle caractérise les sources qui apportent plusieurs fois la même information. Elle est utilisée pour réduire les incertitudes et les imprécisions.
- **la complémentarité** : elle décrit des sources qui apportent des informations sur des grandeurs différentes. Elle est exploitée lors de la fusion pour avoir une information plus complète et lever les ambiguïtés.

Nous avons donc proposé ici une définition de termes que l’on rencontre fréquemment en fusion de données, et que l’on rencontrera dans la suite de ce chapitre.

### 5.2.1.3 Sources d’information et objectifs de la fusion en traitement d’images

Dans ce mémoire, nous nous intéressons plus particulièrement à la fusion en traitement d’images.

En traitement d’images, les sources d’information peuvent être de différentes sortes :

- **Plusieurs images du même capteur** : il s’agit par exemple, dans le cas de l’imagerie sonar, d’images issues d’une séparation en sous-bandes de fréquences de données issues d’un seul capteur. Les informations apportées par chacune des sous-bandes peuvent être suffisamment complémentaires pour être intéressantes lors de la fusion. Ce peut être aussi le cas de différentes vues issues d’un seul capteur imageant une région sous différents angles.
- **Plusieurs images de capteurs différents** : il s’agit d’images issues, par exemple, de plusieurs sonars de types ou de fréquences différentes (un sonar détecteur, basse fréquence, et un sonar classifieur, plus haute fréquence, par exemple). Ce type de problème est assez courant, surtout en imagerie satellitaire (capteurs visuels, infra-rouge, ...).
- **Plusieurs informations extraites d’une même image** : il s’agit de situations dans lesquelles on extrait divers types d’information d’une image à l’aide de plusieurs détecteurs, opérateurs, classifieurs (un exemple de fusion de résultats d’algorithmes de détection est présenté dans [Dob01]), etc. C’est cet aspect qui nous intéresse, puisque nous disposons d’une seule image représentant une région donnée du fond marin.

L'objectif de la fusion peut également être différent d'une application à l'autre. Ainsi, les principaux problèmes pour lesquels la fusion peut être utilisée sont :

- **la détection** : l'objectif est de valider l'hypothèse de présence ou d'absence de l'objet recherché.
- **la reconnaissance ou classification** : l'objet détecté est associé à l'une des familles d'objets connus ou attendus en fonction de différents critères (morphologiques, géométriques, ...). Des exemples d'algorithmes de classification de mines sous-marines, basés sur un processus de classification ont été proposés dans [RPB04] et [QBMF05], à partir d'une base de modèles pour les ombres projetées.
- **l'identification** : ceci constitue l'étape suivant la reconnaissance, et consiste à associer l'objet identifié et reconnu à un prototype unique de sa classe. Par exemple, pour un véhicule, l'étape de reconnaissance consiste à le classer comme "voiture" et l'identification donnera sa marque, son modèle, sa fonction (voiture de police, ...), etc.
- **la segmentation** : l'objectif est alors d'avoir une sélection précise des objets, sous forme de régions ou de contours.

Comme le laisse prévoir le titre de ce mémoire, et le premier chapitre, l'objectif du processus de fusion proposé sera la détection des objets enfouis, et à plus forte raison ceux qui sont posés sur le fond marin.

## 5.2.2 Différentes méthodes de fusion et choix de la méthode

### 5.2.2.1 Etat de l'art des processus de fusion pour la détection d'objets

Pour détecter les objets en acoustique sous-marine, à partir d'un processus de fusion, plusieurs méthodes de combinaison des informations existent.

Les méthodes les plus classiques sont basées sur des approches probabilistes. Ainsi, pour chaque paramètre à fusionner, un modèle statistique est estimé et utilisé pour la combinaison. La combinaison peut alors se faire par vraisemblance (par LLRT, *Log-Likelihood Ratio Test* par exemple [ALFD96]), éventuellement après orthogonalisation [AFD97, AFD01, AFD03b, AFD03a]. Elle peut également se faire en utilisant un classifieur bayésien ou à Machine à Vecteur de Support (SVM, *Support Vector Machine*) [DC02], ou simplement une méthode de "vote" [MvdBB<sup>+</sup>01].

Une autre méthode de fusion largement utilisée est l'utilisation des réseaux de neurones [PG04].

Enfin, une alternative aux méthodes probabilistes sont les théories des possibilités (un exemple sur des profils sismiques dans [Val01]), et de l'évidence, basée sur les fonctions de croyance [Mil01].

### 5.2.2.2 Choix de la méthode de fusion

Les méthodes probabilistes ont l'avantage de reposer sur des bases mathématiques solides. Basées sur une interprétation "fréquentiste" des problèmes physiques [Blo96], elles

ont fait l'objet de nombreux travaux utilisant des outils de modélisation (lois paramétriques aux propriétés bien étudiées) et d'apprentissage des modèles.

Mais elles ont des inconvénients [Blo03]. Tout d'abord, elles ne permettent pas aisément de distinguer les notions d'incertitude et d'imprécision. De plus, les méthodes probabilistes nécessitent une étape d'apprentissage à partir d'un volume de données important. Si on ne dispose pas de ces données (peu d'images, ou des zones caractéristiques de petite taille), l'estimation des probabilités *a priori* est délicate. Elles ont besoin en outre d'une très forte granularité dans l'établissement des hypothèses : c'est-à-dire qu'il faut définir un modèle permettant de séparer efficacement les différentes possibilités. En effet, les méthodes probabilistes permettent de raisonner sur des singletons (ensembles formés d'une seule hypothèse) seulement : le doute n'est pas explicite, considérant que les hypothèses sont équiprobables dans le cas d'un doute entre plusieurs hypothèses (les probabilités sont réparties entre elles).

Les ensembles flous ou la théorie de l'évidence permettent d'évaluer une appartenance partielle du résultat à une hypothèse ou à un ensemble d'hypothèses sans en privilégier aucune. Le doute est alors parfaitement exprimé. Ces théories tiennent compte de l'incertitude et de l'imprécision des informations utilisées, grâce à l'utilisation d'ensembles flous. De plus, elles ne nécessitent pas un apprentissage important, n'ayant pas besoin de modèle de distribution. Elles permettent, par contre, d'inclure des connaissances *a priori*, qui peuvent être fournies par un expert.

La théorie de l'évidence semble alors être la plus adaptée à notre problème de détection en imagerie sonar. En effet, la limitation dans le nombre de données ne permet pas d'effectuer une phase d'apprentissage complète et la théorie de l'évidence accepte des modèles définis à des granularités différentes (plus ou moins de précision dans les hypothèses). De plus, l'objectif de notre étude est d'aider l'expert dans sa prise de décision à partir des éléments qu'il a en sa possession (en fonction de son expérience, de ses connaissances, ...). La théorie de l'évidence permet alors une interprétation plus riche, le doute étant explicitement défini.

## 5.2.3 Théorie de l'évidence

### 5.2.3.1 Principe de la théorie

La théorie de l'évidence, que certains préfèrent appeler théorie des fonctions de croyance ou théorie de Dempster-Shafer, est relativement récente, surtout par rapport aux théories probabilistes, et date des années 1970. Née après l'invention des ensembles flous par Zadeh [Zad65] en 1965, qui introduit des théories qui ne sont plus directement reliées aux probabilités, la théorie des croyances a été développée par Shafer [Sha76] en 1976. Elle a été formalisée et a acquis une base mathématique solide avec Smets<sup>2</sup> et les TBM (*Transferable Belief Models*) [Sme90]. Son utilisation en fusion de signaux et d'images est elle relativement récente.

---

<sup>2</sup><http://iridia0.ulb.ac.be/~psmets>

Le principal atout de cette théorie est la manipulation de sous-ensembles d'hypothèses et non seulement des singletons, ce qui permet une plus grande souplesse dans la modélisation que les théories probabilistes. Elle permet de plus de modéliser l'incertitude, l'imprécision et même l'ignorance. Elle donne également une évaluation du conflit entre les sources.

### 5.2.3.2 Modélisation

La théorie de l'évidence représente l'imprécision et l'incertitude de l'information à l'aide de fonctions de masse  $m$ , de plausibilité  $Pl$  et de croyance  $Cr$  [Sme00]. Si l'on note  $\Omega$  l'ensemble des hypothèses, appelé espace de discernement, ces fonctions sont définies sur les sous-ensembles de  $\Omega$ , appelés propositions ou classes, et pas seulement sur les singletons.

La masse d'évidence  $m(A)$  de la proposition  $A$  exprime le degré de confiance que l'on peut avoir dans celle-ci sans privilégier aucune des hypothèse la composant. La fonction  $m$  est alors définie par :

$$\begin{aligned} m : 2^\Omega &\rightarrow [0, 1] \\ A &\mapsto m(A) \end{aligned} \quad (5.1)$$

$2^\Omega$  désignant l'ensemble des parties (propositions) de l'ensemble des hypothèses  $\Omega$ . Généralement, si on fait l'hypothèse d'un monde clos (toutes les solutions possibles sont représentées dans  $\Omega$ ), on impose les conditions suivantes pour définir  $m$  :

$$m(\emptyset) = 0 \quad (5.2)$$

et une normalisation :

$$\sum_{A \subseteq \Omega} m(A) = 1 \quad (5.3)$$

Une fonction de croyance  $Cr$  est une fonction totalement croissante (au sens des ensembles), définie de la même manière que  $m$  sur  $2^\Omega$  (équation 5.1), avec  $Cr(\emptyset) = 0$  et  $Cr(\Omega) = 1$ . Etant donnée une fonction de masse  $m$ , la fonction  $Cr$  définie par :

$$\forall A \in 2^\Omega, Cr(A) = \sum_{B \subseteq A} m(B) \quad (5.4)$$

est une fonction de croyance. Inversement, à partir d'une fonction de croyance  $Cr$  définie comme une fonction totalement croissante telle que  $Cr(\emptyset) = 0$  et  $Cr(\Omega) = 1$ , on peut définir une fonction de masse par :

$$\forall A \in 2^\Omega, m(A) = \sum_{B \subseteq A} (-1)^{|A|-|B|} Cr(B) \quad (5.5)$$

où  $|A|$  désigne le cardinal de l'ensemble  $A$ . On peut avoir  $Cr(A) = 1$  et  $Cr(B) = 1$  avec  $A \neq B$  et donc :

$$\sum_{A \subseteq \Omega} Cr(A) \geq 1 \quad (5.6)$$

La fonction de croyance définit ainsi la confiance totale que l'on a dans une proposition  $A$ .

Une fonction de plausibilité est définie également comme la fonction de masse de  $2^\Omega$  dans  $[0, 1]$ , avec  $Pl(\emptyset) = 0$  et  $Pl(\Omega) = 1$  :

$$\forall A \in 2^\Omega, Pl(A) = \sum_{B \cap A \neq \emptyset} m(B) \quad (5.7)$$

On a alors le lien avec la fonction de croyance suivant :

$$\forall A \in 2^\Omega, Pl(A) = 1 - Cr(\bar{A}) \quad (5.8)$$

avec  $\bar{A}$  le complémentaire de  $A$ . On a donc forcément  $Pl(A) \geq Cr(A)$  pour tout  $A$ .

La plausibilité mesure la confiance maximale que l'on peut avoir dans la proposition  $A$ .

L'intervalle  $[Cr(A), Pl(A)]$  est appelé intervalle de confiance et sa longueur est une mesure de l'ignorance que l'on a sur une proposition  $A$ . La probabilité inconnue d'un événement  $A$ , si celle-ci existe, est comprise dans cet intervalle.

### 5.2.3.3 Combinaison

Pour chaque source d'information que l'on cherche à fusionner, nous définissons une fonction de masse.

Soit  $m_i$  ( $i = 1 \dots l$ ) la fonction de masse définie pour la source  $i$ . La combinaison conjonctive des fonctions de masse est effectuée selon la somme orthogonale définie pour toute proposition  $A$  de  $2^\Omega$  par :

$$(m_1 \oplus m_2 \oplus \dots \oplus m_l)(A) = \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1) m_2(B_2) \dots m_l(B_l) \quad (5.9)$$

Des justifications axiomatiques de cette règle ont été proposées dans [Sme90].

La masse affectée à l'ensemble vide ( $\emptyset$ ) peut être non nulle avec cette formule. Une normalisation du résultat de la combinaison a été proposée par Dempster, afin d'annuler cette masse, a été proposée dans [Sha76] et [Sme90]. Il est cependant préférable, à mon avis, de ne pas réaliser cette normalisation afin de conserver la présence de ce conflit. Celui-ci peut provenir soit d'un défaut de fiabilité des sources, soit d'informations sur des phénomènes différents, et il est intéressant de pouvoir connaître l'origine du conflit et éventuellement de le corriger en introduisant d'autres informations.

La relation de combinaison présentée dans l'équation 5.9 est commutative et associative. La fonction de masse définie par :

$$m_0(\Omega) = 1 \quad \text{et} \quad \forall A \subseteq \Omega, A \neq \Omega, m_0(A) = 0 \quad (5.10)$$

est l'élément neutre pour cette combinaison. En effet, cette fonction décrit une source complètement non informative, ne permettant de distinguer aucune proposition.

Cette règle de combinaison n'est applicable que sous l'hypothèse d'indépendance des sources. Mais cette indépendance doit être comprise au sens cognitif [Blo03], ce qui est bien moins contraignant qu'une indépendance statistique. On considère alors que les sources sont indépendantes si chacune n'utilise pas le résultat obtenu par les autres (comme un expert qui se ferait une opinion sans consulter les autres experts, pourtant du même domaine de compétence).

Une fois la combinaison effectuée, les valeurs de la croyance et de la plausibilité du résultat se rapprochent : on dit que les fonctions de masse sont plus focalisées que les masses initiales (elles sont définies sur des ensembles plus petits). Le conflit (masse de l'ensemble vide) s'il existe, par contre, augmente.

Cette combinaison constitue donc le coeur du processus de fusion, les résultats servant à la décision. C'est ce que nous allons voir dans l'application de ces outils à la détection sur les images sonar.

## 5.3 Application à la détection en imagerie sonar

Après avoir présenté les principes de la fusion de données, et en particulier de la théorie de l'évidence, nous allons voir comment appliquer ce processus à la détection en imagerie sonar.

### 5.3.1 Choix des paramètres et schéma de la fusion

#### 5.3.1.1 Paramètres fusionnés

Tout au long de ce mémoire, nous avons proposé des méthodes de détection en utilisant des paramètres statistiques extraits localement (sur des fenêtres de calcul) des images sonar. On a ainsi pour chaque pixel de l'image une valeur associée à chacun de ces paramètres. Nous avons mis en évidence dans les chapitres 3 et 4 l'intérêt de ces paramètres dans la détection, en particulier des objets enfouis dans le sédiment marin.

Ces paramètres statistiques sont :

- **l'écart-type (ordre 2) et la moyenne (ordre 1)**, ces deux paramètres étant liés par un coefficient de proportionnalité, afin de réaliser une segmentation qui peut être automatisée, comme il est décrit dans le chapitre 3 ;
- **le skewness (ordre 3)** : grandeur statistique, dont l'utilisation est décrite dans le chapitre 4 ;
- **le kurtosis (ordre 4)** : grandeur statistique, dont l'utilisation est décrite dans le chapitre 4.

La figure 5.1 présente une superposition des courbes COR obtenues avec ces trois paramètres sur les images C et D, comparées avec le résultat obtenu avec un simple seuillage (ces images ont été choisies pour leurs différences de propriétés, telles que la résolution, ...). Nous pouvons donc constater que, comme nous l'avons vu dans les chapitres précédents,

les méthodes de détection basées sur ces paramètres statistiques sont toutes plus performantes qu'un simple seuillage. L'utilisation du simple niveau de gris dans un processus de détection ne paraît donc pas *a priori* intéressante. En ce qui concerne les autres paramètres, il paraît assez difficile de départager leurs pouvoirs de détection. Nous avons remarqué dans le chapitre 4 que le skewness semblait plus performant pour la détection que le kurtosis, mais pour les paramètres des premiers ordres (moyenne et écart-type, la méthode de détection associée étant la segmentation), il est difficile de les départager des deux autres : la probabilité de détection est légèrement plus élevée pour de faibles taux de fausse alarme, mais la différence n'est pas flagrante.

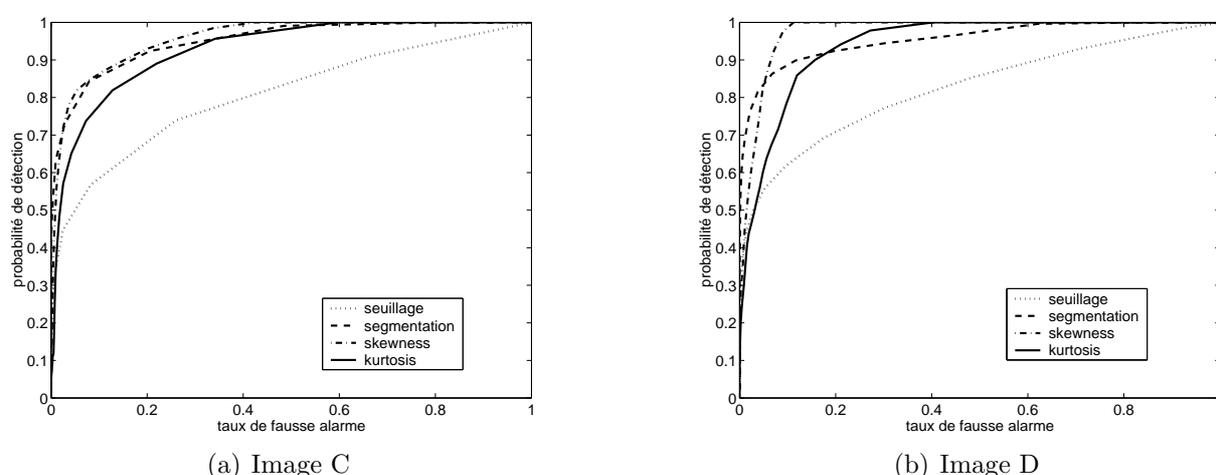


FIG. 5.1 – Performances des différents paramètres extraits des images SAS en terme de détection.

### 5.3.1.2 Schéma de la fusion

L'objectif de la fusion de données est de rendre la détection des objets plus performante en combinant les différents paramètres dans un processus de fusion. Ce processus de fusion peut être décrit par la figure 5.2. Ces paramètres sont donc combinés après avoir subi des traitements appropriés (focalisation et reconstruction pour les SOS, chapitre 4) et en utilisant des connaissances associées (seuils en écart-type et en moyenne évalués par la segmentation automatique, chapitre 3). Les résultats de la fusion pourront alors être utilisés pour la prise de décision en les représentant de manière adéquate.

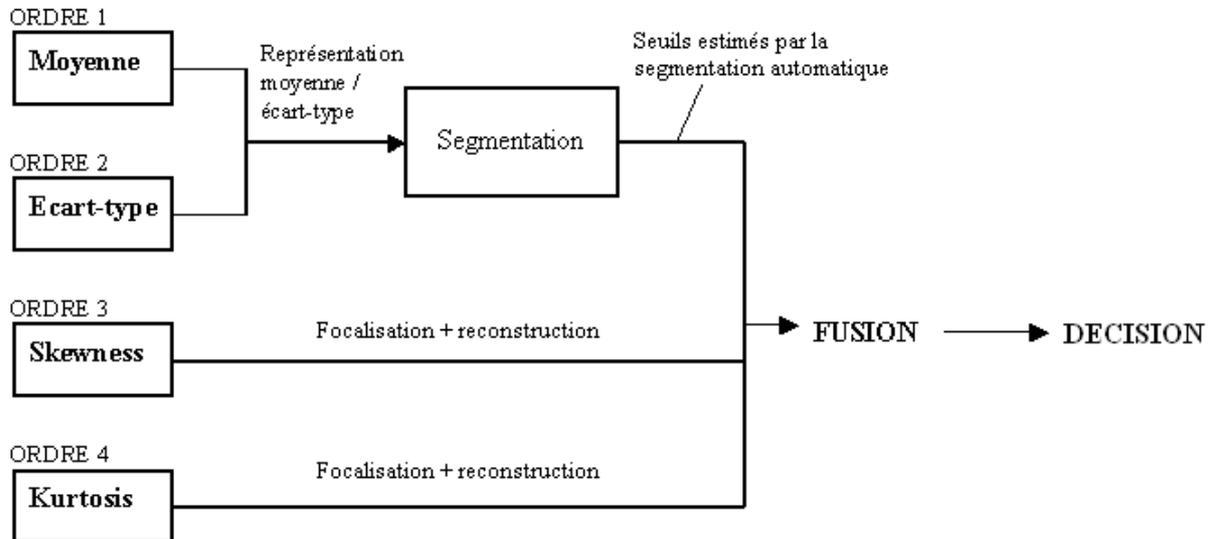


FIG. 5.2 – Schéma du processus de fusion.

## 5.3.2 Choix des hypothèses et définition des fonctions de masse

### 5.3.2.1 Choix des hypothèses

L'objectif du processus de fusion présenté dans ce mémoire est de détecter les objets présents sur l'image sonar, à partir de leurs échos. L'espace de discernement  $\Omega$ , concernant chacun des pixels, sera donc composé de deux hypothèses :

- “**objet**” ( $O$ ) pour les pixels de l'image susceptibles d'appartenir à un écho d'un objet ;
- “**non objet**” ( $NO$ ) pour ceux qui sont susceptibles d'appartenir au fond bruité (ou éventuellement à une ombre projetée).

Utilisant la théorie de l'évidence, l'ensemble des propositions  $2^\Omega$  est composé de trois éléments : les singletons  $O$  et  $NO$ , et le sous-ensemble  $\{O, NO\}$ , que l'on notera par abus de notation  $O \cup NO$  et que l'on nommera “doute”. En plus de ces éléments, le sous-ensemble vide  $\emptyset$  sera nommé “conflit”.

### 5.3.2.2 Définition des fonctions de masse

À chaque paramètre  $s$  mesuré, concernant un pixel, on associe une distribution de masse sur  $2^\Omega$ . Nous avons choisi de les définir à partir de fonctions inspirées des sous-ensembles flous afin de laisser une certaine flexibilité dans la décision. Ces fonctions sont telles que pour toute valeur  $s$  du paramètre, on a :

$$\sum_{A \in 2^\Omega} m_s(A) = 1 \quad (5.11)$$

La définition des fonctions de masse s'effectue à partir de trapèzes, décrits à partir

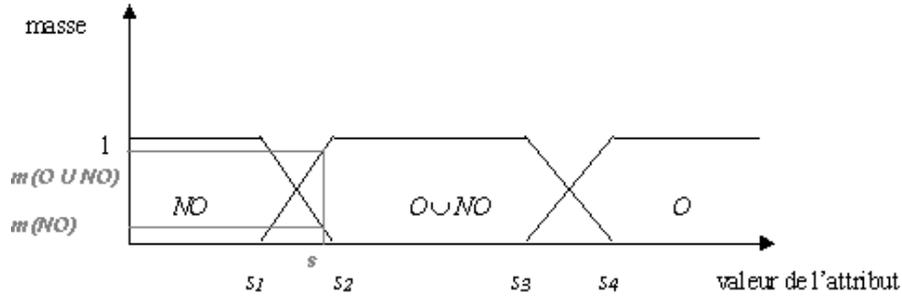


FIG. 5.3 – Définition des fonctions de masse.

des seuils  $s_1$ ,  $s_2$ ,  $s_3$  et  $s_4$  (figure 5.3). Ces seuils sont fixés à partir des connaissances statistiques que nous avons sur les images sonar au niveau local et global. Ils tiennent également compte de notre souci de minimiser les conflits et surtout le nombre d’objets, potentiellement dangereux, non détectés.

**Les deux premiers ordres : moyenne et écart-type** En ce qui concerne les paramètres des deux premiers ordres, nous raisonnons sur le couple (moyenne,écart-type comme nous l’avons fait pour la segmentation dans le chapitre 3. La figure 5.4 présente un exemple de définition des fonctions de masses pour les paramètres des deux premiers ordres statistiques. Par exemple, les pixels ayant leur représentant dans le repère moyenne / écart-type en dessous des seuils définis par un écart-type inférieur à  $s_1$  ont une masse égale à un pour la proposition “non objet” et nulle pour les autres. Pour les pixels ayant leur représentant entre  $s_1$  et  $s_2$  ont une masse décroissant de 1 à 0 pour la proposition “non objet”, allant de 0 à 1 pour la proposition “doute” selon leur position dans le repère moyenne / écart-type, les masses variant linéairement en fonction de l’écart-type (la moyenne étant calculée à partir de chaque valeur de l’écart-type selon la relation de proportionnalité évaluée par la loi de Weibull; voir le chapitre 3 et la figure 5.4). Il en est ensuite de même pour les autres valeurs, en fonction des seuils.

Nous définissons alors les fonctions de masses associées au paramètre écart-type à partir des valeurs de seuils suivantes :

$$\begin{aligned}
 s_1 &= \mathcal{M}(\hat{\sigma}_F) \\
 s_2 &= \mathcal{M}(\hat{\sigma}_F) + \sqrt{\mathcal{V}(\hat{\sigma}_F)} \\
 s_3 &= \sigma_s - \frac{1}{2}\sqrt{\mathcal{V}(\hat{\sigma}_F)} \\
 s_4 &= \sigma_s + \frac{1}{2}\sqrt{\mathcal{V}(\hat{\sigma}_F)}
 \end{aligned} \tag{5.12}$$

avec  $\mathcal{M}(\hat{\sigma}_F)$  et  $\mathcal{V}(\hat{\sigma}_F)$  respectivement la moyenne et la variance de l’estimateur  $\hat{\sigma}_F$  de l’écart-type des pixels de la fenêtre de calcul  $F$ . Ces grandeurs sont calculées à partir des équations 3.17 et 3.18, en supposant que  $\sigma_F$  (valeur réelle de l’écart-type sur la fenêtre  $F$ ) est égale à l’écart-type de l’image au niveau global, calculé à partir des paramètres de la loi de Weibull estimée (chapitre 2).  $\sigma_s$  est le seuil en écart-type estimé pour la segmentation automatique.

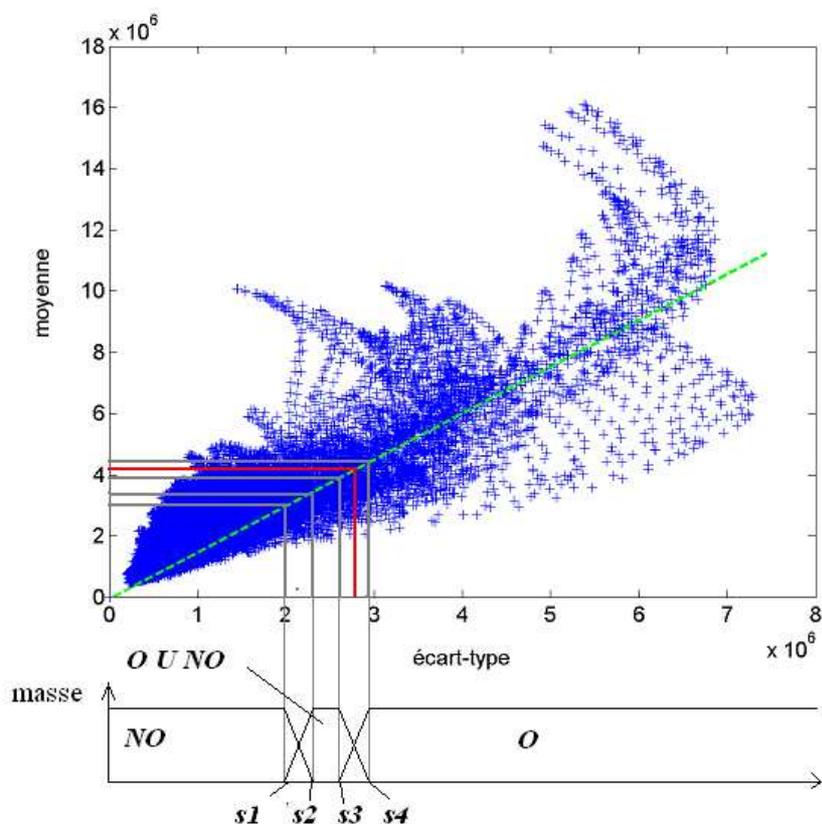


FIG. 5.4 – Définition des fonctions de masse pour les premiers ordres statistiques : exemple de l’image D (on a  $s_2 - s_1 = s_4 - s_3 = \sqrt{\mathcal{V}(\hat{\sigma}_F)}$ , en rouge : seuils déterminés par la segmentation automatique).

Cette définition des fonctions de masse met alors une masse égale à 1 (et donc à zéro pour les autres classes) sur la proposition “non objet” lorsque la valeur de l’écart-type est inférieure à l’écart-type du fond (seuil  $s_1$ ), au biais de l’estimateur près. Ensuite, nous mettons une masse égale à 0,5 aux classes “objet” et “doute” (et zéro pour les autres) au seuil estimé par la segmentation automatique (figure 5.4). En effet, nous avons fixé ce seuil, au moyen d’un critère d’entropie, de manière “optimale” de telle sorte qu’au dessous on atteigne le fond bruité. Le choix de ces masses permet alors d’avoir une masse sur la classe “objet” supérieure à celle du “doute” au dessus de ce seuil, et inversement en dessous. La variance de l’estimateur de l’écart-type nous permet ensuite de définir les transitions entre classes, en ayant une certaine symétrie dans la définition des fonctions de masse.

**Les ordres supérieurs** En ce qui concerne les statistiques d’ordres supérieurs (skewness et kurtosis), il n’est pas possible d’utiliser directement les grandeurs : nous sommes obligés d’effectuer au préalable une focalisation et une reconstruction afin d’avoir des valeurs élevées au niveau des échos (voir le chapitre 4). Les propriétés statistiques ne peuvent

pas nous aider à définir les fonctions de masse, le processus de focalisation nous faisant perdre ces propriétés. Nous utilisons alors l'histogramme des valeurs sur l'image SOS et surtout son histogramme cumulé (figure 5.6). En effet, nous avons vu dans le chapitre 4 que les pixels associés au fond bruité ont des valeurs faibles sur les images des SOS, et que le nombre de pixels associés aux échos sont plus élevés mais sont beaucoup moins nombreux proportionnellement à l'image. Nous utilisons ces propriétés pour définir les fonctions de masse.

Avant de les définir, rappelons tout d'abord que les résultats des SOS présentent de nombreux artefacts (structures en forme de croix généralement) empêchant une bonne définition des régions correspondant aux échos, contrairement aux paramètres moyenne et écart-type. Nous décidons alors de donner une masse nulle à la classe "objet" pour toutes les valeurs des SOS, en répartissant la masse sur les propositions "non objet" et "doute" en fonction du paramètre (figure 5.5). Ces paramètres vont donc seulement permettre de prendre une décision sur la certitude de l'appartenance au fond bruité.

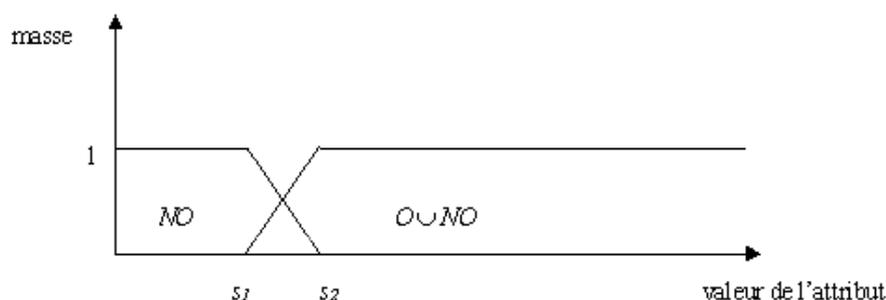


FIG. 5.5 – Définition des fonctions de masse pour les statistiques d'ordres supérieurs.

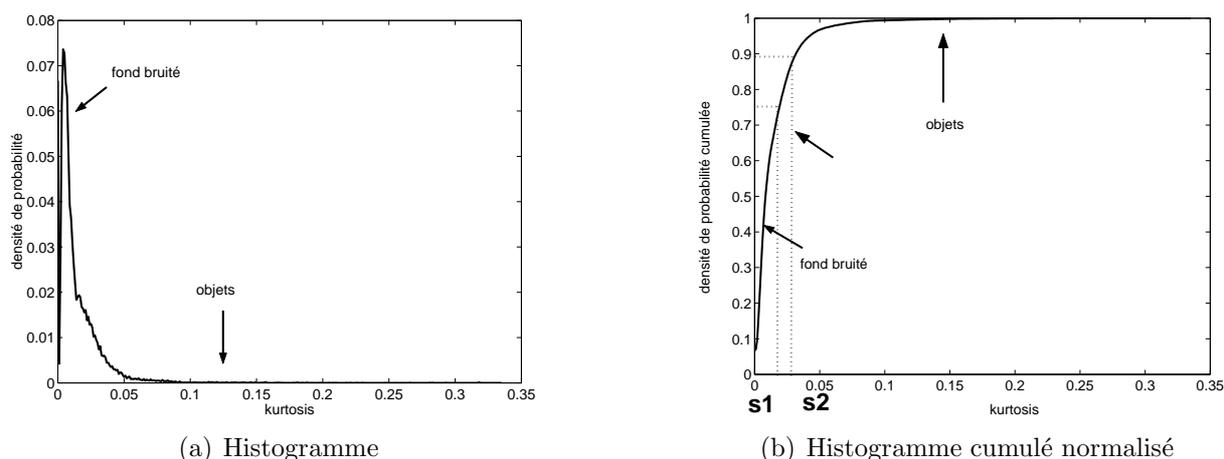


FIG. 5.6 – Exemples d'histogramme et d'histogramme cumulé normalisés de l'image des kurtosis (focalisée et reconstruite) de l'image C.

Les seuils  $s_1$  et  $s_2$  restant à fixer se calculent sur l'histogramme cumulé normalisé de valeur  $\mathcal{H}(s)$  pour la valeur  $s$  du paramètre (valeur du pixel sur les images des SOS) :

$$\begin{aligned} s_1 &= \mathcal{H}^{-1}(0, 75) \\ s_2 &= \mathcal{H}^{-1}(0, 90) \end{aligned} \quad (5.13)$$

Ainsi, nous supposons qu'au moins les trois quarts de l'image appartiennent au fond bruité, ce qui est une hypothèse tout à fait réaliste. Par contre une proportion inférieure à un dixième des échos laisse supposer la présence d'objets, tout en maintenant le doute.

### 5.3.2.3 Combinaison

La combinaison entre les différents paramètres s'effectue selon l'équation 5.9. En pratique, le calcul de la combinaison s'effectue en établissant une table de décision [Blo03]. Par exemple, pour la fusion de deux paramètres, nous avons le tableau 5.1.

TAB. 5.1 – Table de décision pour la fusion de deux paramètres.

	$O$	$O \cup NO$	$NO$
$O$	$O$	$O$	$\emptyset$
$O \cup NO$	$O$	$O \cup NO$	$NO$
$NO$	$\emptyset$	$NO$	$NO$

L'expression des masses associées à chaque proposition de  $2^\Omega$  s'écrit :

$$\begin{aligned} (m_1 \oplus m_2)(O) &= m_1(O).m_2(O) + m_1(O).m_2(O \cup NO) + m_1(O \cup NO).m_2(O) \\ (m_1 \oplus m_2)(O \cup NO) &= m_1(O \cup NO).m_2(O \cup NO) \\ (m_1 \oplus m_2)(NO) &= m_1(NO).m_2(NO) + m_1(NO).m_2(O \cup NO) + m_1(O \cup NO).m_2(NO) \end{aligned} \quad (5.14)$$

et pour le conflit ( $\emptyset$ ) :

$$(m_1 \oplus m_2)(\emptyset) = m_1(O).m_2(NO) + m_1(NO).m_2(O) \quad (5.15)$$

Nous utilisons ensuite la propriété d'associativité de la combinaison orthogonale pour ajouter un troisième paramètre au processus de fusion (on ajoute alors au conflit de la combinaison la masse associée au conflit de la combinaison des paramètres précédents).

### 5.3.3 Evaluations de la performance de classification

Nous nous donnons plusieurs outils d'évaluation du processus de fusion afin d'estimer la performance de la détection à partir de la méthode proposée. Certaines de ces grandeurs sont spécifiques à la fusion de données (non spécificité, erreur et conflit), d'autres sont plus générales (courbe COR).

### 5.3.3.1 Évaluation de la performance en absolu

L'évaluation de la performance de la détection par fusion de données passe d'abord par l'estimation de la qualité de la distribution de masse du résultat.

Le premier critère permettant d'évaluer cette qualité est la non-spécificité [KW99]. Celle-ci mesure l'ambiguïté de l'information apportée par la distribution de masse : elle est plus faible si l'essentiel de la masse d'évidence porte sur un singleton (réponse certaine), et plus élevée si il porte sur une proposition de cardinal élevé (doute portant sur plusieurs hypothèses). Pour une distribution de masse  $m$ , elle se calcule selon la formule :

$$\mathcal{N}(m) = \sum_{A \in 2^\Omega} m(A) \cdot \log_2 |A| \quad (5.16)$$

L'intervalle de définition de cette grandeur est :

$$0 \leq \mathcal{N}(m) \leq \log_2 |\Omega| \quad (5.17)$$

La borne inférieure (zéro) est atteinte dans le cas où il existe  $a_i \in \Omega$  telle que  $m(\{a_i\}) = 1$  (certitude totale) et atteint la borne maximale pour  $m(\Omega) = 1$  (ignorance totale). Ainsi, plus la non-spécificité est proche de zéro, meilleure est la distribution de masse, celle-ci donnant une "réponse" précise. Une fonction de masse non spécifique donnera peu de réponses fausses, mais n'apportera pas beaucoup d'information (par exemple : "Paul est grand"). Par contre, une fonction spécifique est plus précise, mais augmente le risque d'erreur (par exemple : "Paul mesure 1,80m").

Si on applique cette évaluation à notre problème, composé seulement de deux hypothèses, le calcul de la non-spécificité ne porte seulement que sur la masse associée à la classe "doute". Notre travail portant sur des images, il nous paraît alors intéressant de définir une **densité de non-spécificité** évaluant la qualité du résultat de la fusion sur toute l'image. Cette densité de non-spécificité se calcule alors selon la formule :

$$d_{\mathcal{N}(m)} = \frac{1}{N} \sum_{i=1}^N m_i(O \cup NO) \quad (5.18)$$

$N$  étant la taille de l'image en pixels et  $m_i(O \cup NO)$  la masse de la classe "doute", à l'issue de la fusion, pour le pixel  $i$ . Cette densité a une valeur comprise entre 0 et 1 inclus, et plus cette densité est proche de zéro, meilleur est le résultat de la fusion en terme de certitude dans la "réponse".

Nous avons vu précédemment que, même si l'on a cherché à le réduire au maximum lors de la définition des fonctions de masse, du conflit peut apparaître dans le résultat de la fusion. De même que précédemment, nous pouvons définir une **densité de conflit** ou **conflictualité** :

$$d_{\mathcal{C}(m)} = \frac{1}{N} \sum_{i=1}^N m_i(\emptyset) \quad (5.19)$$

Cette densité est comprise entre 0 et 1. Bien entendu, plus cette densité est proche de zéro, plus les sources d'information sont cohérentes et plus le résultat est fiable.

### 5.3.3.2 Evaluation de la performance à partir de la vérité terrain

Afin de valider le résultat de la fusion à partir de la vérité terrain, nous pouvons reprendre certains outils décrits précédemment en ajoutant cette connaissance supplémentaire. Nous entendons par vérité terrain, dans notre cas, les images contenant les masques telles que décrites dans le chapitre 3 : ces images sont construites par un expert qui a sélectionné les régions susceptibles de contenir des échos d'objets. Nous considérons sur ces images certaines régions comme appartenant à la classe "objet", les autres à la classe "non objet".

Plus généralement, si l'on note  $B$  la vérité terrain ( $B \in \Omega$ ), l'indice de non-spécificité de la distribution de masse  $m$  connaissant la vérité terrain  $B$  peut s'évaluer, à partir de l'équation 5.16, par :

$$\mathcal{N}(m/B) = \sum_{A/B \subset A} m(A) \cdot \log_2 |A| \quad (5.20)$$

C'est la somme des éléments contenant  $B$  pondérée par leur cardinal. En appliquant directement cette formule à notre problème, on peut définir un **indice de densité de non-spécificité** associé à l'hypothèse  $B$  par :

$$d_{\mathcal{N}(m/B)} = \frac{1}{N} \sum_{i=1}^N m_i(O \cup NO) \cdot \delta_i(B) \quad (5.21)$$

où  $\delta_i(B)$  est égal à 1 si le pixel  $i$  est classé dans  $B$  ("objet" ou "non objet") dans la vérité terrain, zéro sinon, avec  $B \in \Omega = \{O, NO\}$ . Ce paramètre permet d'évaluer l'origine de la non-spécificité calculée précédemment (équation 5.18), si elle provient d'un doute sur la détection des objets (ce qui est le plus grave) ou du fond. On retrouve bien entendu :

$$d_{\mathcal{N}(m)} = d_{\mathcal{N}(m/O)} + d_{\mathcal{N}(m/NO)} \quad (5.22)$$

Nous pouvons également définir un indice d'erreur connaissant la vérité terrain par :

$$\mathcal{E}(m/B) = \sum_{A \cap B = \emptyset} m(A) \log_2(|A| + 1) \quad (5.23)$$

L'**indice de densité d'erreur** associé à l'hypothèse  $B$ , appliqué à notre problème peut alors se calculer avec :

$$d_{\mathcal{E}(m/B)} = \frac{1}{N} \sum_{i=1}^N m_i(\bar{B}) \cdot \delta_i(B) \quad (5.24)$$

avec  $B \in \{O, NO\}$  et  $\bar{B}$  le complémentaire de  $B$ . On peut également définir une **densité d'erreur** totale par :

$$d_{\mathcal{E}(m)} = d_{\mathcal{E}(m/O)} + d_{\mathcal{E}(m/NO)} \quad (5.25)$$

L'erreur nous donnera une mesure de la qualité de la détection selon qu'elle se trompe sur la nature d'un pixel ("objet" ou "non objet"). Elle devra être le plus faible possible.

### 5.3.3.3 Probabilité de détection et taux de fausse alarme

Comme nous l'avons fait dans les chapitres précédents, nous pouvons évaluer la performance en terme de détection du processus de fusion proposé sur les images sonar. Pour cela, nous devons raisonner sur les images des croyances et des plausibilités associées à la classe "objet", que l'on peut seuiller à différentes valeurs comprises entre 0 et 1 ( $\alpha$ -coupes). On ajoute ainsi une étape de décision. Pour chaque seuil, nous obtenons une image binaire sur laquelle nous pouvons calculer un taux de fausse alarme et une probabilité de détection permettant la construction d'une courbe COR (chapitre 3), que l'on pourra comparer avec celles obtenues avec les méthodes décrites précédemment.

## 5.4 Résultats sur les données sonar

Dans cette partie, nous allons nous intéresser à l'application des outils de fusion de données présentés ci-dessus sur les images SAS utilisées tout au long de ce rapport.

### 5.4.1 Fusion des données sur les images SAS

#### 5.4.1.1 Estimation et combinaison

Nous appliquons le processus de fusion sur l'image C (figure 5.21(a), voir la présentation de cette image chapitre 1). Tout d'abord, on évalue pour chaque pixel la masse associée à chaque proposition ("objet", "doute" et "non objet") en utilisant les définitions des fonctions de masses décrites ci-dessus (figures 5.7, 5.8 et 5.9). Ces différentes images sont combinées en utilisant la règle orthogonale afin d'obtenir les images des masses associées à chaque proposition (figure 5.10). On peut alors obtenir une image des croyances (ce qui correspond, dans notre cas, à l'image des masses de la classe "objet") et des plausibilités (correspondant à la somme des masses associées aux classes "objet" et "doute") associées à la classe "objet" (figure 5.11).

Nous pouvons donc constater que tous les objets présents sur l'image SAS ont été bien détectés, les croyances, et à plus forte raison les plausibilités, ayant des valeurs proches de 1 dans les régions susceptibles de contenir les échos. L'image des plausibilités présente de nombreuses régions de valeurs élevées vers le bas. La plausibilité présente un résultat à la limite supérieure concernant la détection. De plus, ces régions sont de taille assez faible et sont isolées. Ils pourront donc être éliminés facilement par un filtrage morphologique.

Le doute de la figure 5.7 est diminué par les masses associées à la classe "non objet" des paramètres statistiques d'ordres supérieurs (figures 5.8 et 5.9). Par permutation, on peut

dire également que le doute issu des SOS est limité par les masses “objet” et “non objet” des premiers ordres. Ainsi, les paramètres des premiers ordres donnent une information précise mais présente de nombreuses fausses alarmes (figure 5.7), tandis que les ordres supérieurs donnent peu de fausses alarmes, mais l’information est peu précise (figures 5.8 et 5.9). Est ainsi illustrée la dualité certitude et exactitude, ainsi que la complémentarité entre les différentes grandeurs.

Même si les SOS affectent une masse nulle à la proposition “objet”, l’image des masses “objet” est modifiée par la fusion (comparer les figures 5.7(a) et 5.10(a)). En effet, les masses des SOS associées à la classe “doute” sont multipliées par la masse de la classe “objet” de la segmentation.

Du conflit apparaît à l’issue de la fusion (figure 5.10(d)), mais il reste très faible (masses inférieures strictement à 1) et se situe dans des régions isolées.

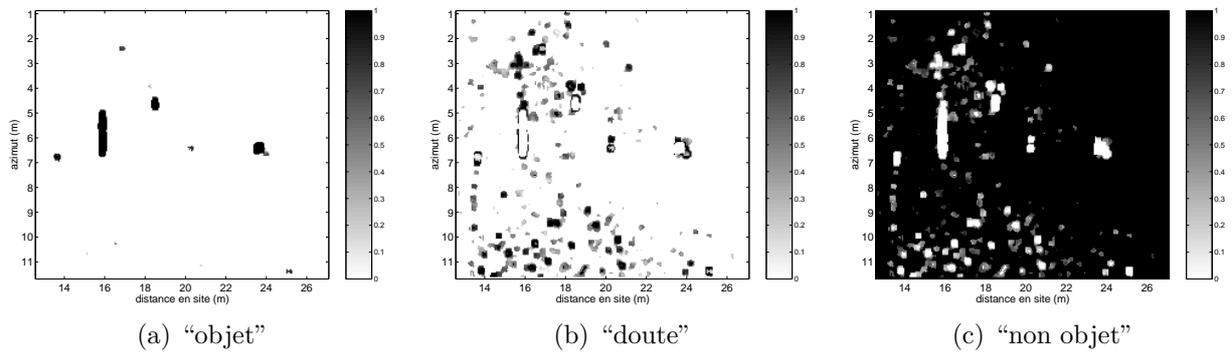


FIG. 5.7 – Images des masses obtenues pour les différentes classes pour le paramètre moyenne / écart-type (segmentation) sur l'image C.

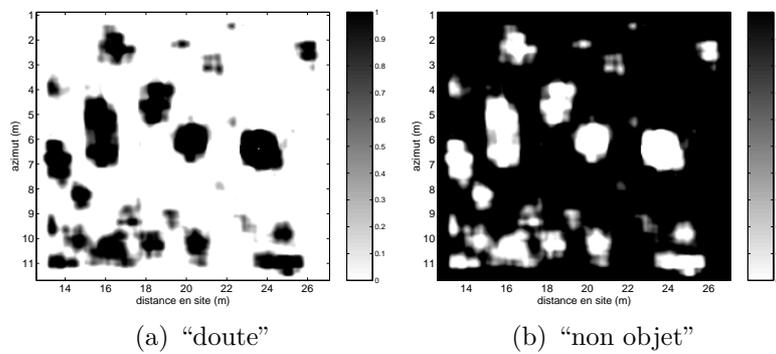


FIG. 5.8 – Images des masses obtenues pour les différentes classes pour le paramètre skewness sur l'image C.

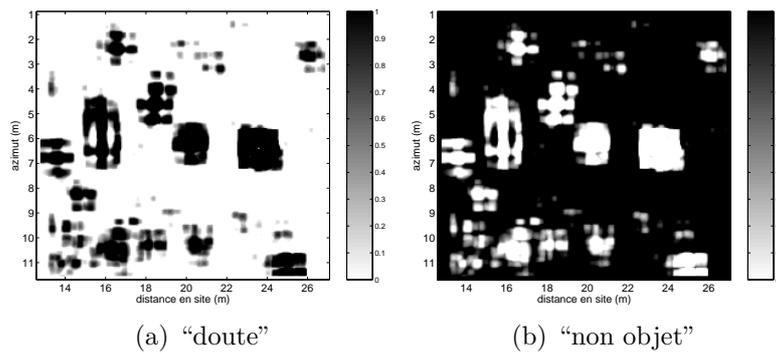


FIG. 5.9 – Images des masses obtenues pour les différentes classes pour le paramètre kurtosis sur l'image C.

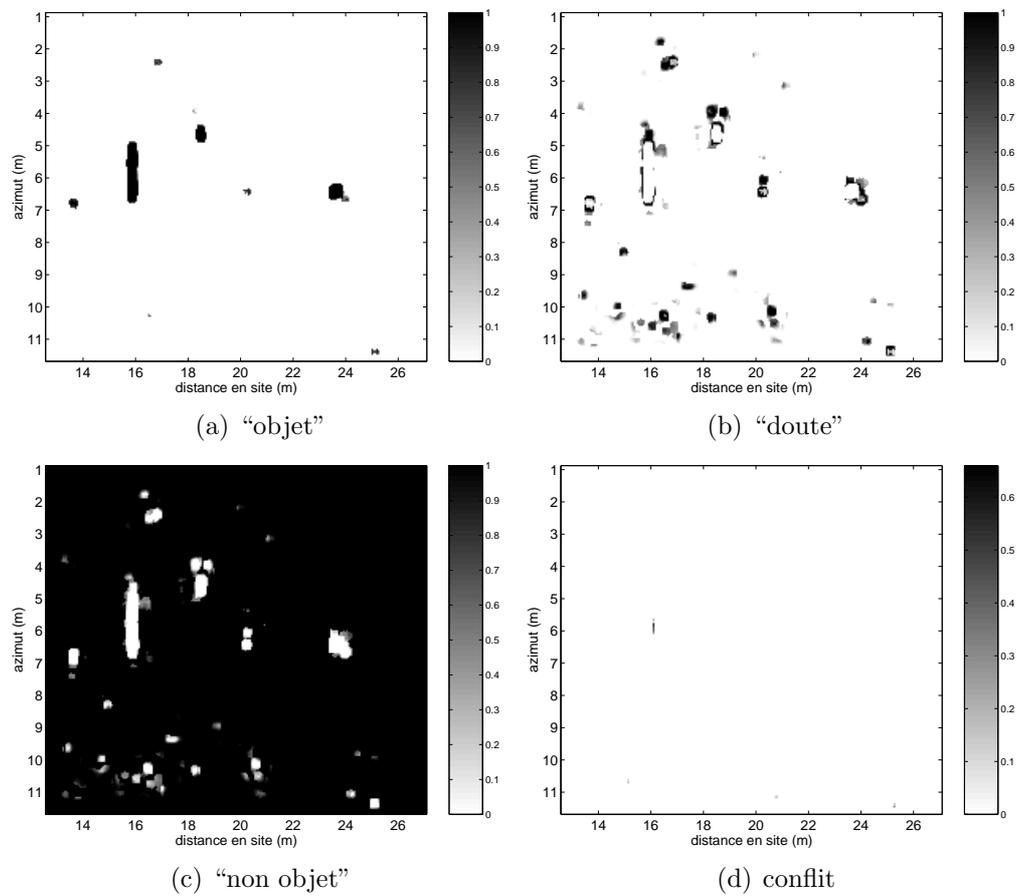


FIG. 5.10 – Images des masses obtenues après fusion des trois paramètres sur l'image C.

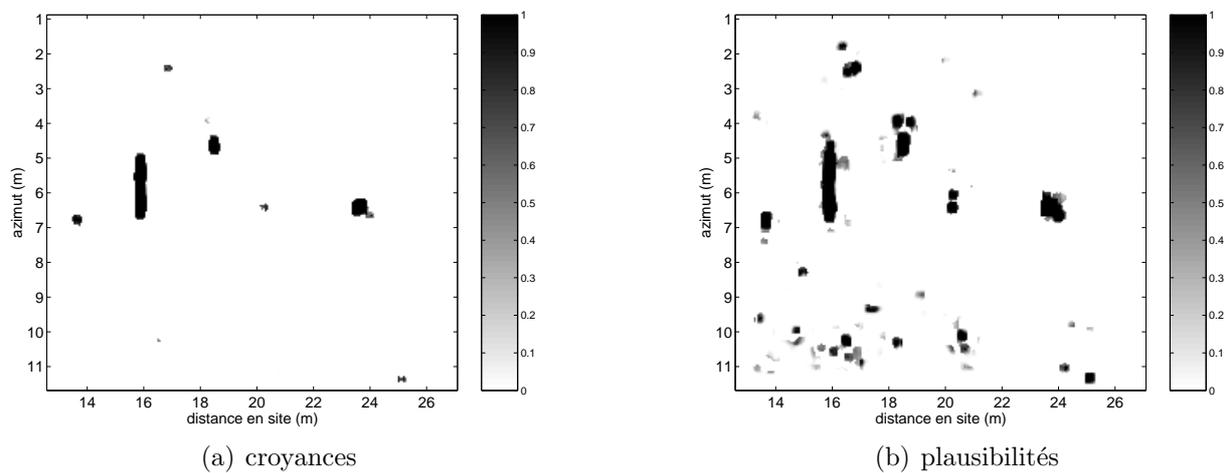


FIG. 5.11 – Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image C.

### 5.4.1.2 Evaluation des performances

Une première évaluation de la performance de la fusion peut se faire en étudiant ce qu’apporte chaque paramètre de la fusion au résultat final. Ceci peut se faire d’abord qualitativement en décomposant les étapes du processus de fusion, en combinant les paramètres deux à deux.

Comme nous l’avons constaté précédemment, nous pouvons voir que la fusion d’un paramètre SOS fait diminuer les masses associées à la classe “doute” (comparer les figures 5.12(b) et 5.13(b) à la figure 5.7(b)). La fusion des trois paramètres fait alors décroître encore plus cette masse (figure 5.10(b)). Ainsi, plus on ajoute de paramètres dans le processus de fusion, plus la réponse est précise.

De plus, nous pouvons constater que le conflit issu de la fusion des trois paramètres ne semble pas augmenter considérablement par rapport à celui de la fusion de deux paramètres, les fonctions de masse ayant été définies afin de le limiter. Il est également à noter que l’ajout d’un paramètre à la fusion “sélectionne” plus précisément les masses “objet”, c’est-à-dire qu’il y a moins de valeurs de masses différentes de 0 et de 1.

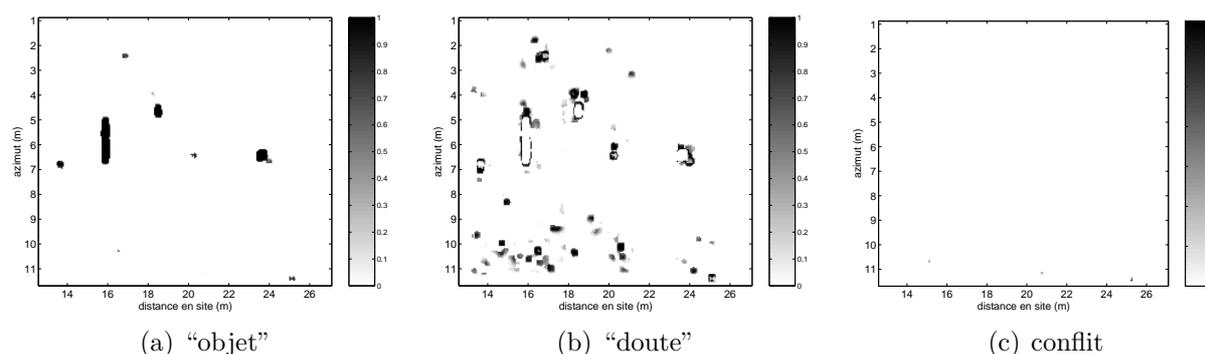


FIG. 5.12 – Images des masses obtenues pour les différentes classes pour la fusion des paramètre moyenne / écart-type (segmentation) et skewness sur l’image C.

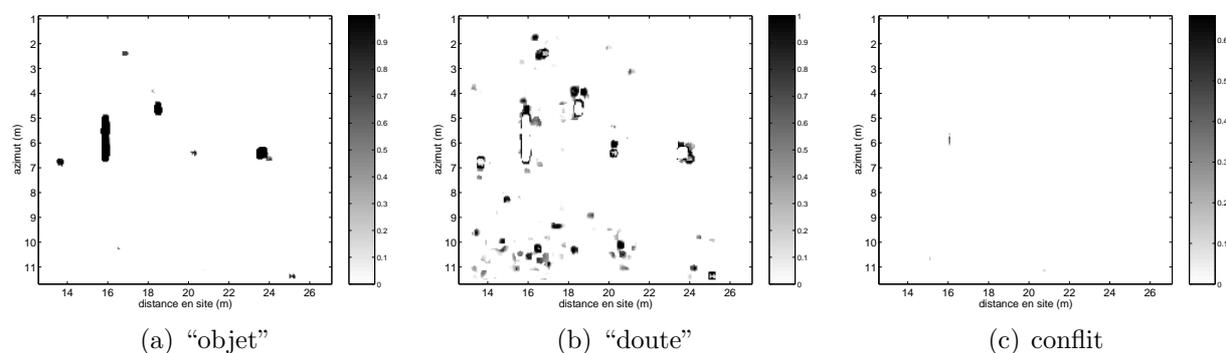


FIG. 5.13 – Images des masses obtenues pour les différentes classes pour la fusion des paramètre moyenne / écart-type (segmentation) et kurtosis sur l’image C.

Une autre mesure des performances peut se faire numériquement au moyen de grandeurs estimées indépendamment de la vérité terrain (densités de conflit et de non-spécificité) ou en fonction de celle-ci (indices de densité de non-spécificité et densités d'erreur). Les résultats obtenus sur les combinaisons des différents paramètres sont consignés dans le tableau 5.2.

Les résultats confirment les remarques qualitatives précédentes :

- La non-spécificité diminue avec l'ajout de paramètres. Notons que cette densité est très importante pour chacun des SOS, et la fusion des deux, à cause de la définition des fonctions de masse (nullité de la masse associée à la classe "objet").
- Le conflit augmente avec l'ajout de paramètres (bien que ce ne soit pas très flagrant dans notre cas, comme nous l'avons vu précédemment).

Avec ces deux grandeurs, nous pouvons évaluer la quantité d'information apportée par chaque paramètre lorsqu'on le fusionne. Ainsi, si l'ajout d'un paramètre ne fait pas diminuer sensiblement la densité de non-spécificité, on peut supposer qu'il n'apporte pas suffisamment d'information. De plus, si la densité de conflit augmente considérablement, on peut dire que ce paramètre est contradictoire avec les autres (fiabilité de la source fournissant ce paramètre, ou des autres sources, ...).

Si la vérité terrain est disponible, on peut avoir accès à de nouvelles informations sur la performance du processus de fusion. Nous pouvons ainsi remarquer que l'ajout des paramètres SOS fait diminuer légèrement l'erreur. Notons que cette erreur est faible pour les SOS. En effet, la définition des fonctions de masse est assez "ambiguë" pour limiter les erreurs (si la masse associée à la proposition "doute" est égale à 1, l'erreur est nulle). Par contre la valeur relativement élevée de l'erreur sur les régions classées comme "objet" s'explique par la taille assez importante des régions sélectionnées par l'expert qui incluent une partie des régions classées comme "fond" par le processus de fusion. Mais elle ne provient pas d'une mauvaise détection dans l'absolu : les échos sont bien détectés, mais sont seulement plus petits que les masques de l'image de référence. Cela sera confirmé plus tard sur les courbes COR où l'on verra que la probabilité de détection maximale atteinte par la fusion n'est pas de 1.

Concernant la non-spécificité, nous pouvons remarquer qu'elle est plus importante pour les pixels "non objet" sur la vérité terrain que pour ceux "objet". Ceci est bon signe pour la fusion, la réponse étant précise dans le cas où on a un objet potentiellement dangereux.

Enfin, nous pouvons construire les courbes COR associées aux résultats de la fusion, au même titre que ce que nous avons fait dans les chapitres précédents, et les comparer à celles obtenues précédemment (figure 5.14 construite avec 50 réalisations).

Notons tout d'abord qu'il n'y a pas de point entre les faibles valeurs de fausses alarmes (jusqu'à 0,03) et le point correspondant au taux 1. Ceci vient du fait qu'à certains pixels de l'image de référence, appartenant aux masques modélisant les échos, correspondent une croyance et une plausibilité nulle, ce qui fait qu'il faut sélectionner tous les points de l'image pour les atteindre (avec une  $\alpha$ -coupe de zéro). Ces pixels ne sont pas du tout représentatifs d'un objet réel, et sont là seulement à cause d'une définition grossière des régions contenant les échos. Expert et fusion sont alors d'avis contraires : l'expert affirme qu'il s'agit d'un objet et la fusion donne une plausibilité nulle pour la proposition "objet". On a alors un taux de fausse alarme et une probabilité de détection maximales, éloignés du point (1,1) (voir la flèche sur la figure 5.14(b)). De même, il existe, à la fois pour la croyance et la plausibilité, des probabilités de détection et de fausse alarme minimales que l'on atteint pour une  $\alpha$ -coupe à 1.

Il est alors intéressant de constater que la croyance présente des taux de fausse alarme, mais aussi des probabilités de détection, plus faibles qu'avec la plausibilité. On retrouve ainsi l'ambivalence certitude / précision que l'on a déjà vu précédemment. Nous pouvons alors constater que les courbes associées à la plausibilité et à la croyance sont au dessus de toutes les autres courbes (ou confondues avec la segmentation en ce qui concerne la croyance), ce qui montre le gain en détection que l'on obtient avec la fusion.

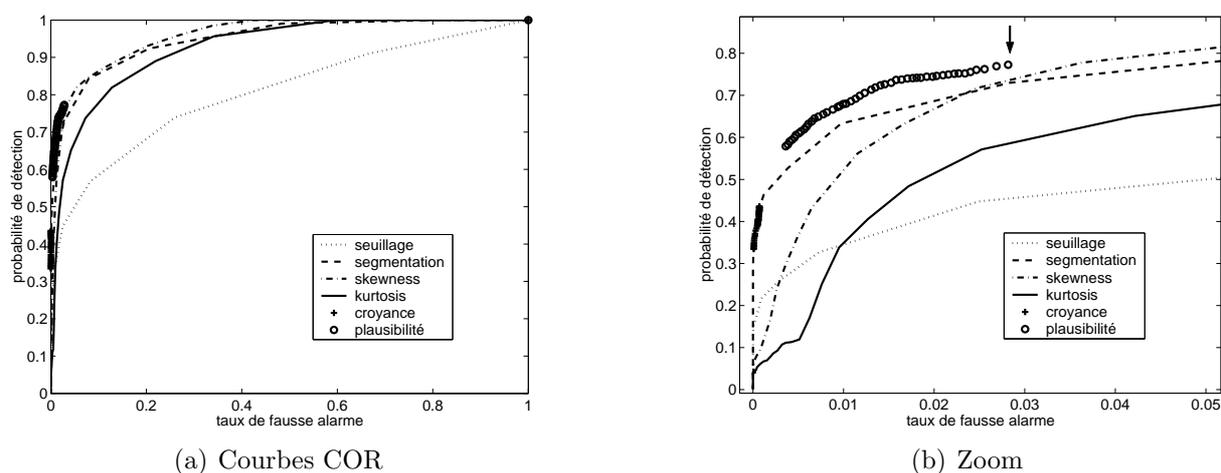


FIG. 5.14 – Courbes COR comparées des trois paramètres fusionnée et des résultats de la fusion (plausibilité et croyance) sur l'image C.

TAB. 5.2 – Performances de la fusion des différents paramètres sur l'image C,  
(12 : moyenne / écart-type (segmentation), 3 : skewness, 4 : kurtosis).

densités	12	3	4	12 + 3	12 + 4	3 + 4	12 + 3 + 4
conflit	<b>0</b>	<b>0</b>	<b>0</b>	<b><math>2,99.10^{-5}</math></b>	<b><math>8,85.10^{-5}</math></b>	<b>0</b>	<b><math>1,05.10^{-4}</math></b>
non-spécificité	<b>0,0510</b>	<b>0,1661</b>	<b>0,1661</b>	<b>0,0238</b>	<b>0,0209</b>	<b>0,1213</b>	<b>0,0190</b>
/O	0,0079	0,0188	0,0175	0,0067	0,0061	0,0174	0,0061
/NO	0,0430	0,1473	0,1486	0,0171	0,0148	0,1039	0,0129
erreur	<b>0,0050</b>	<b>0,0022</b>	<b>0,0035</b>	<b>0,0062</b>	<b>0,0068</b>	<b>0,0035</b>	<b>0,0068</b>
/O	0,0045	0,0022	0,0035	0,0057	0,0063	0,0035	0,0063
/NO	$5,57.10^{-4}$	0	0	$5,2.10^{-4}$	$5,35.10^{-4}$	0	$5,18.10^{-4}$

TAB. 5.3 – Performances de la fusion des différents paramètres sur l'image D,  
(12 : moyenne / écart-type (segmentation), 3 : skewness, 4 : kurtosis).

densités	12	3	4	12 + 3	12 + 4	3 + 4	12 + 3 + 4
conflit	<b>0</b>	<b>0</b>	<b>0</b>	<b><math>4,06.10^{-4}</math></b>	<b><math>5,27.10^{-4}</math></b>	<b>0</b>	<b><math>5,28.10^{-4}</math></b>
non-spécificité	<b>0,0081</b>	<b>0,0159</b>	<b>0,1628</b>	<b>0,0039</b>	<b>0,0035</b>	<b>0,1220</b>	<b>0,0034</b>
/O	0,0018	0,0135	0,0120	0,0018	0,0015	0,0120	0,0015
/NO	0,0063	0,1454	0,1508	0,0022	0,0019	0,1100	0,0019
erreur	<b>0,0065</b>	<b><math>4,46.10^{-5}</math></b>	<b>0,0016</b>	<b>0,0060</b>	<b>0,0062</b>	<b>0,0016</b>	<b>0,0062</b>
/O	0,0044	$4,46.10^{-5}$	0,0016	0,0044	0,0046	0,0016	0,0046
/NO	0,0020	0	0	0,0016	0,0016	0	0,0016

### 5.4.1.3 Résultats sur d'autres données sonar

Regardons maintenant les résultats que nous obtenons avec les autres données SAS à notre disposition. Ainsi, nous présentons les résultats obtenus en terme de croyance et de plausibilité, ainsi que les courbes COR (figures 5.16, 5.18 et 5.20) pour les images D (image de la figure 5.22(a)), E (image de la figure 5.23(a)) et B (image de la figure 5.24(a)). De plus, des critères de performance ont été calculés sur l'image D, afin de les comparer à ceux de l'image C. La fusion a bien entendu été réalisée avec les mêmes définitions des fonctions de masses.

Toutes les remarques effectuées sur l'image C se trouvent confirmées sur ces images. Nous pouvons même constater sur les courbes COR un gain en détection plus intéressant que sur l'image C, surtout en ce qui concerne la croyance. Notons toutefois que l'ajout du paramètre skewness ne paraît pas modifier le résultat de la fusion sur l'image D, les densités de non-spécificité, d'erreur et de conflit n'étant pratiquement pas différentes lors de la fusion des trois paramètres par rapport à la fusion des paramètres "segmentation" et kurtosis.

Une autre remarque concerne l'image B, qui, rappelons le, ne contient *a priori* que deux objets posés sur le fond marin. En effet, de nombreuses petites régions de croyance et de plausibilité élevées apparaissent en dehors des échos principaux associés aux deux objets. Ceci vient de la haute résolution de cette image qui met en évidence les irrégularités du terrain. L'inclusion de paramètres de formes (la taille par exemple), en passant au niveau objet du processus de détection, supprimerait aisément ces artefacts.

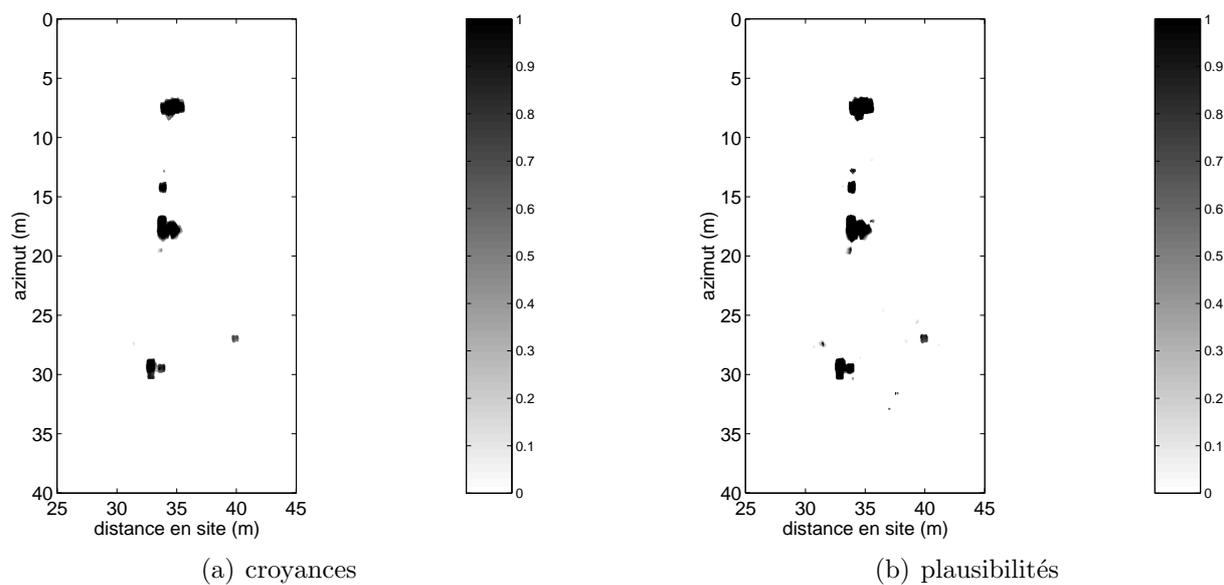


FIG. 5.15 – Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image D.

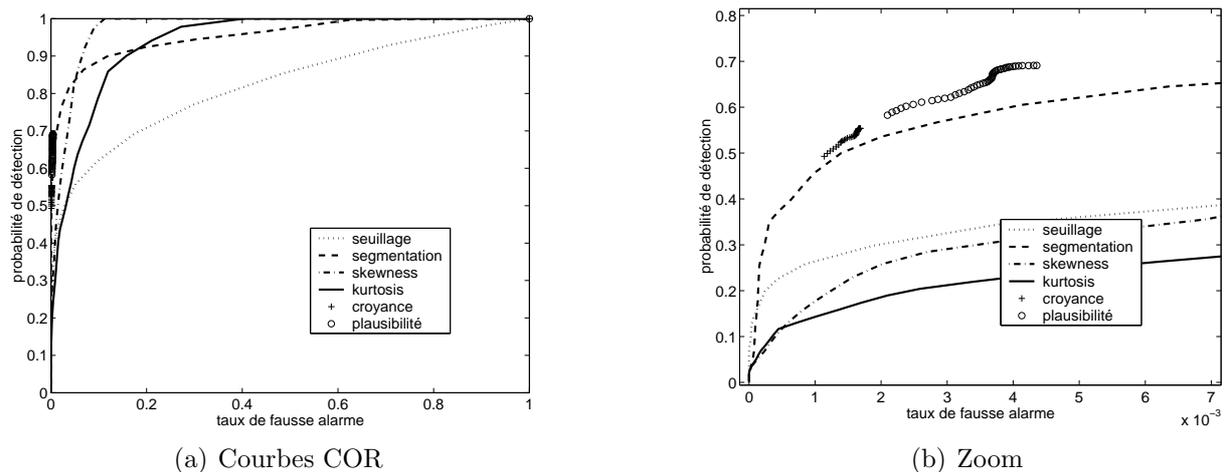


FIG. 5.16 – Courbes COR comparées des trois paramètres fusionnés et des résultats de la fusion (plausibilité et croyance) sur l'image D.

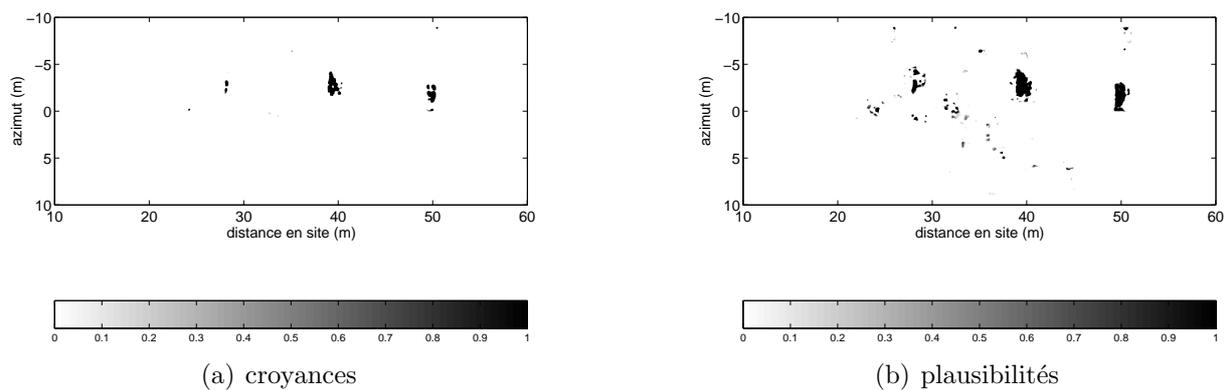


FIG. 5.17 – Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image E.

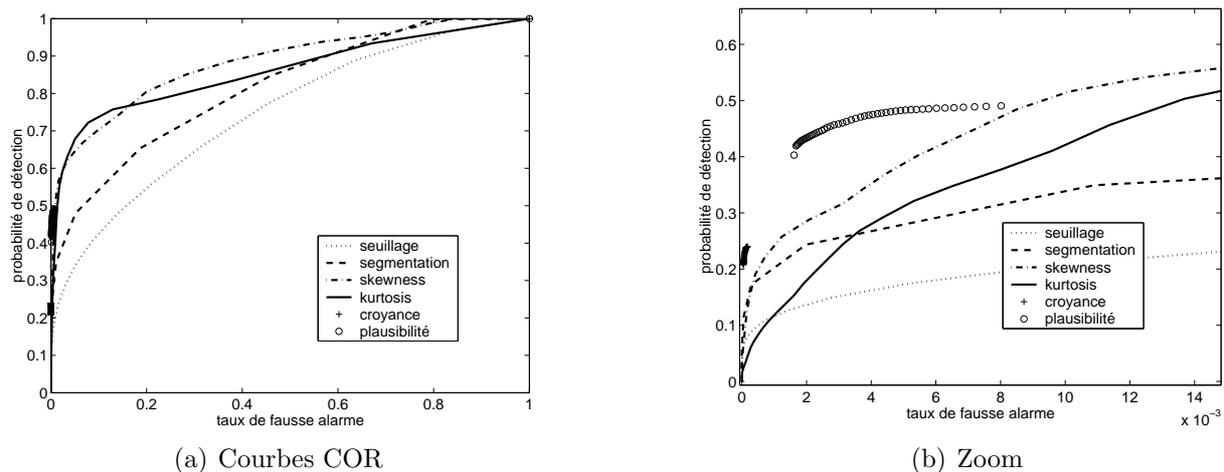


FIG. 5.18 – Courbes COR comparées des trois paramètres fusionnés et des résultats de la fusion (plausibilité et croyance) sur l'image E.

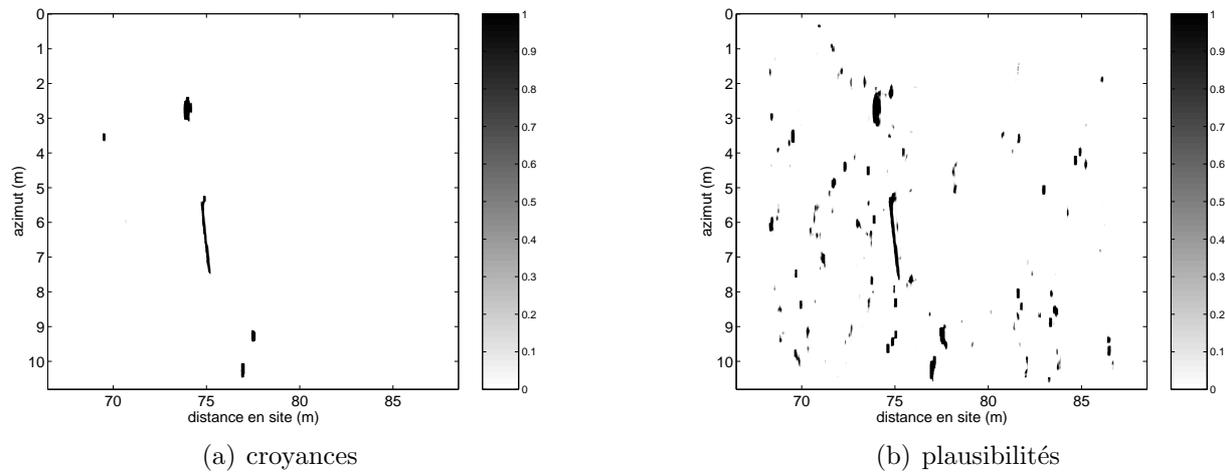


FIG. 5.19 – Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image B.

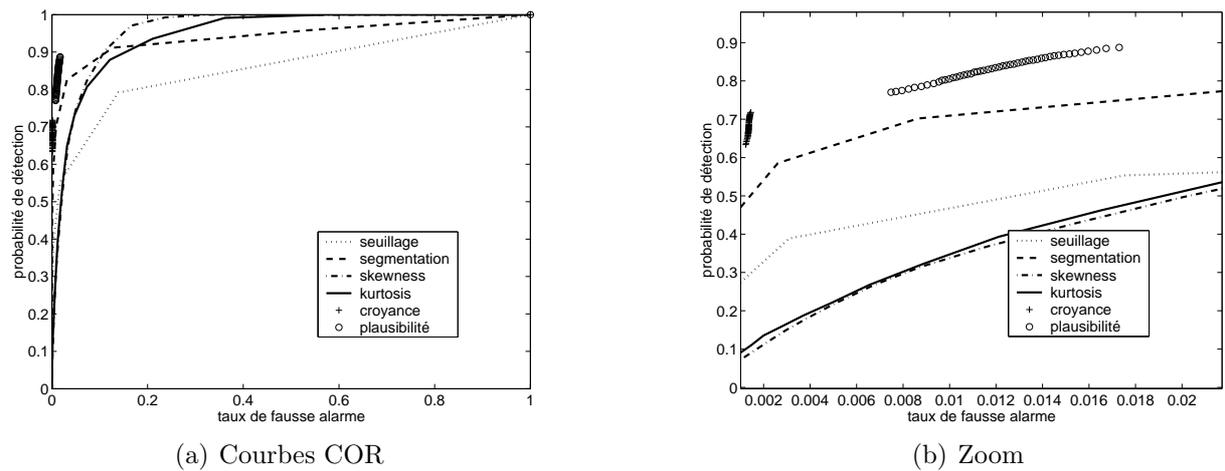


FIG. 5.20 – Courbes COR comparées des trois paramètres fusionnés et des résultats de la fusion (plausibilité et croyance) sur l'image B.

## 5.4.2 Représentation des résultats

Maintenant que nous avons vu l'intérêt de la fusion de données en détection sous-marine, nous allons voir comment représenter les résultats trouvés afin d'aider l'expert dans sa prise de décision.

Pour cela, il existe deux types de représentations des résultats :

- les représentations “binaires” permettant d'avoir une séparation de l'image en régions selon qu'elles sont susceptibles de contenir un objet ou pas,
- les représentations utilisant les images d'origine et transposant les résultats de la fusion sur celle-ci, afin de mettre en évidence les régions d'intérêt.

Nous allons développer chacune d'entre elles dans cette partie.

### 5.4.2.1 Classification

La première catégorie de représentations des résultats est celle qui n'utilise que les résultats de la fusion afin de classer chaque pixel de l'image selon sa valeur de masse, de croyance ou de plausibilité.

Une solution simple est de réaliser une  $\alpha$ -coupe (ce qui revient pour nous à faire un seuillage des images correspondantes) des résultats de la croyance ou de la plausibilité de la proposition “objet” [Blo03]. Par exemple, on peut décider que les pixels ayant une croyance supérieure à 0,5 appartiennent à des échos. On réalise alors une  $\alpha$ -coupe à 0,5 et on obtient une image binaire avec d'un côté les pixels associés aux échos, et les autres au fond. Le défaut de cette méthode est que l'on laisse le seuil à l'appréciation de l'opérateur.

Une méthode plus “automatique” est d'associer à chaque pixel l'hypothèse (“objet” ou “non objet”) ayant la croyance la plus élevée [Blo03]. On obtient également une image binaire. On peut faire la même chose avec la plausibilité. Notons que pour nos images, les deux grandeurs donnent le même résultat (voir les figures 5.21(d), 5.22(d), 5.23(d) et 5.24(d), les pixels “objet” étant à la valeur 1, les autres à zéro).

Une variante de cette représentation est celle que nous appelons “classification” : à chaque pixel, on associe la classe (y compris le conflit) ayant la masse d'évidence la plus élevée. Nous obtenons alors une image divisée en 4 régions selon l'appartenance de chaque pixel (figures 5.21(c), 5.22(c), 5.23(c) et 5.24(c)). Ce type de représentation n'est donc plus binaire et laisse à l'expert de la liberté dans l'interprétation des résultats.

De nombreuses autres représentations, du même type, des résultats de la fusion ont été proposées dans la littérature [Blo03].

### 5.4.2.2 Transposition des résultats sur l'image originale

Les représentations décrites ci-dessus sont très bien adaptées à une détection “robotisée” : elles permettent de définir des régions d'intérêt qu'un système automatisé pourrait explorer plus en détail afin d'identifier l'objet.

Mais pour un expert humain, ces représentations lui font perdre des informations (environnement, relief, intensité, . . .), présentes sur l'image d'origine et qui pourraient lui être utiles dans l'identification des objets.

Nous proposons alors de combiner les résultats de la fusion à l'image d'origine. Pour cela, nous pouvons effectuer une pondération des valeurs des pixels en fonction de la croyance ou de la plausibilité : on multiplie la valeur du pixel d'origine par un facteur élevé si la croyance (ou la plausibilité) est proche de 1, par un facteur plus faible si celle-ci est proche de zéro. Par exemple, sur nos images SAS, nous utilisons un facteur de pondération allant de 0,3 pour une plausibilité nulle, à 1 pour une plausibilité de 1, ce facteur variant linéairement en fonction de la plausibilité (figures 5.21(b), 5.22(b), 5.23(b) et 5.24(b)). Ceci donne un effet de rehaussement des échos par rapport au fond sans que celui-ci disparaisse.

Une autre solution est d'effectuer un filtrage adaptatif de l'image sonar d'origine en fonction de ces mêmes croyance ou plausibilité. Un exemple d'un tel filtrage est présenté en annexe.

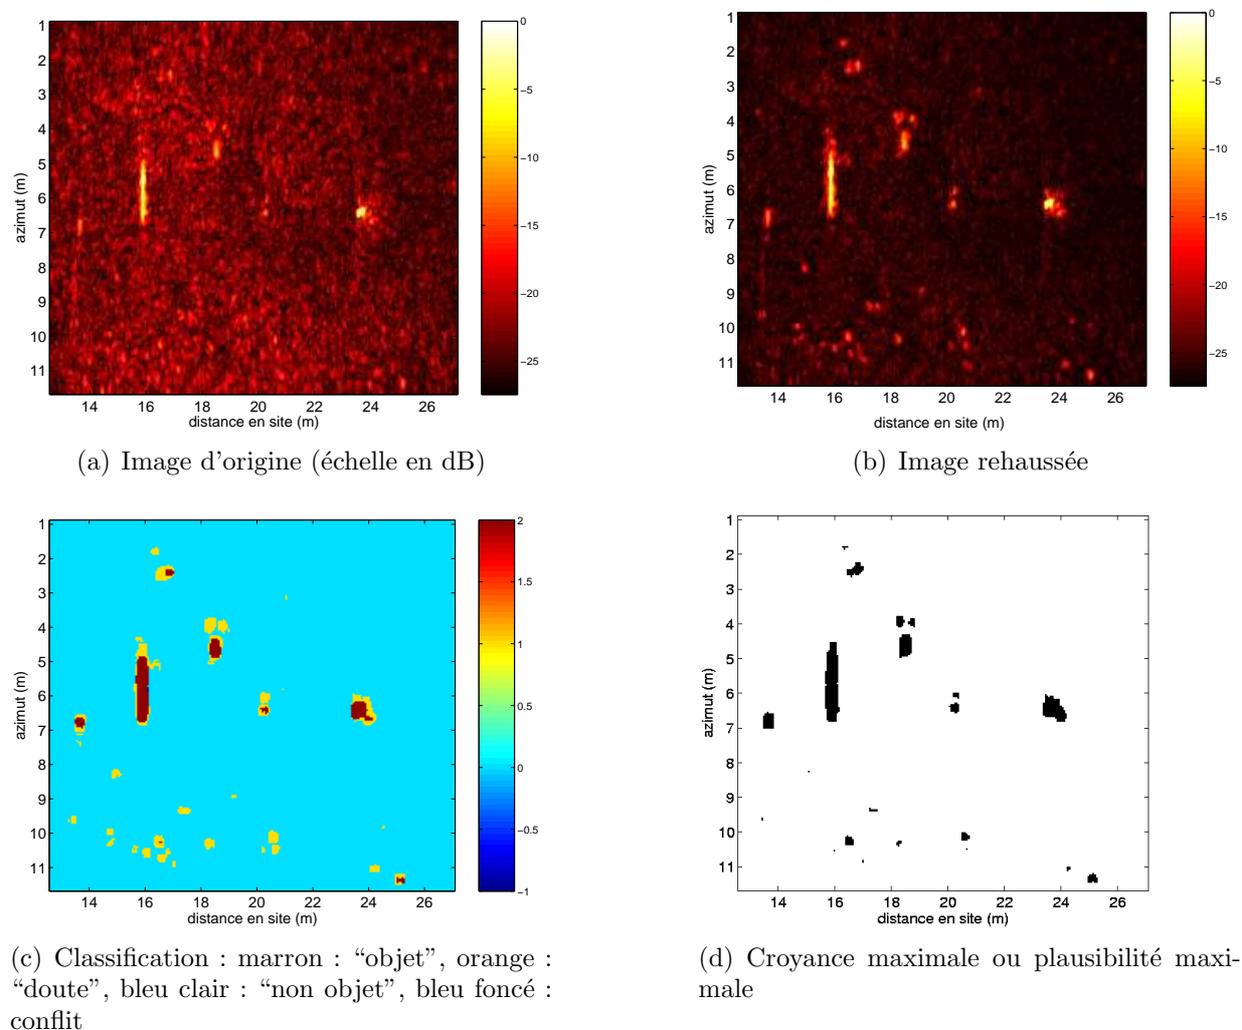


FIG. 5.21 – Présentations des résultats de la fusion sur l'image C.

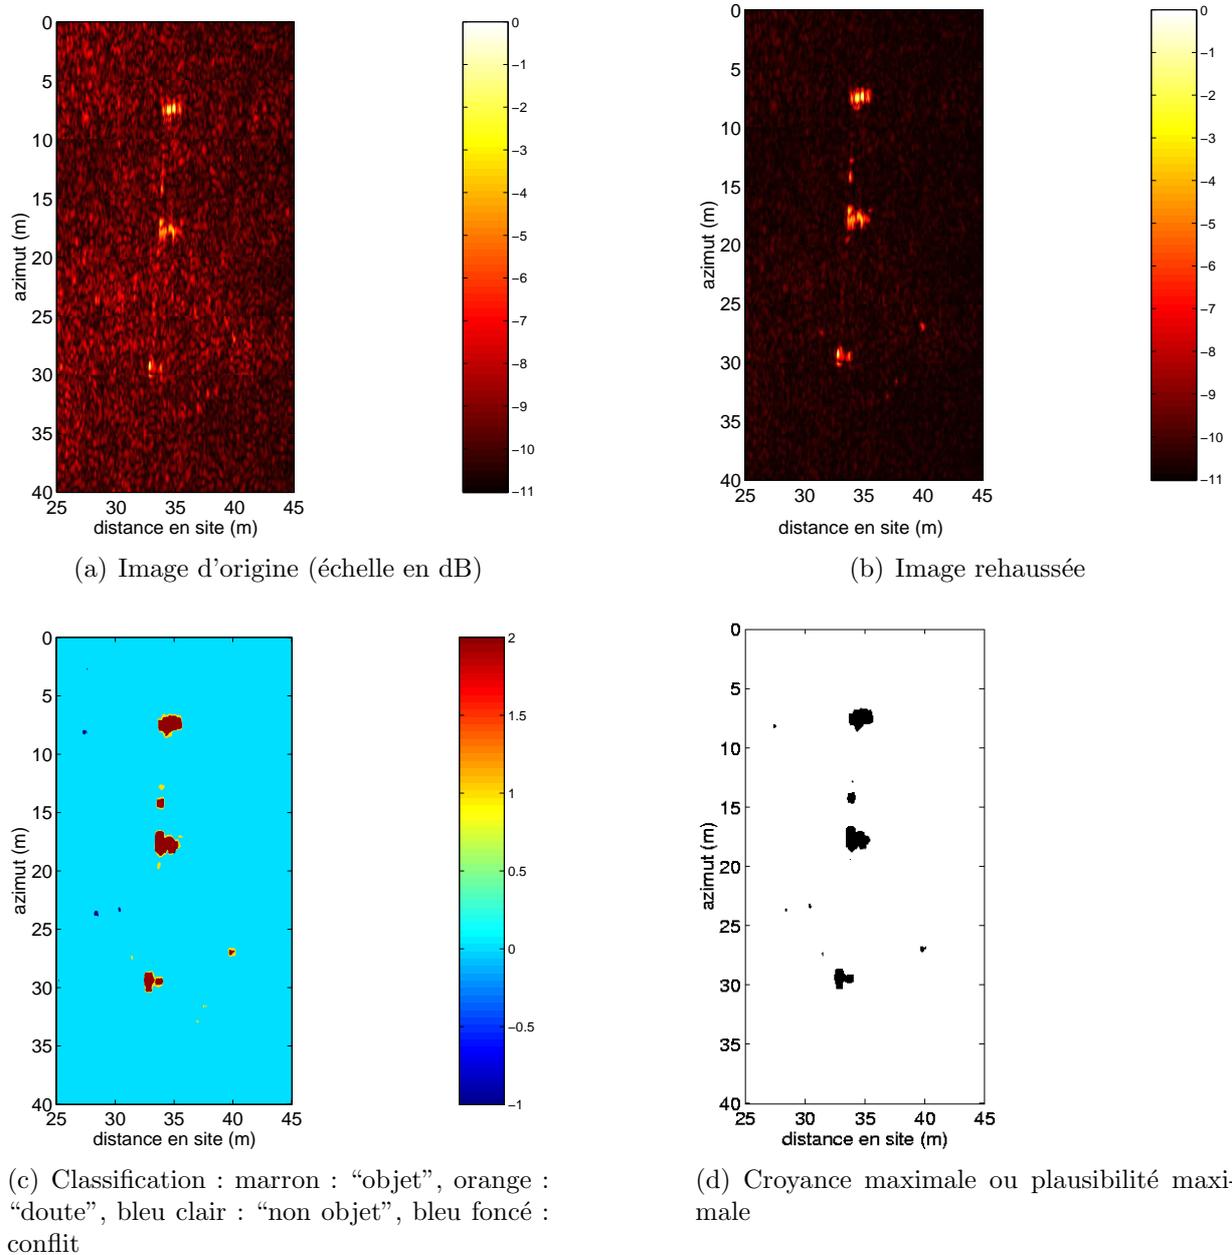


FIG. 5.22 – Présentations des résultats de la fusion sur l'image D.

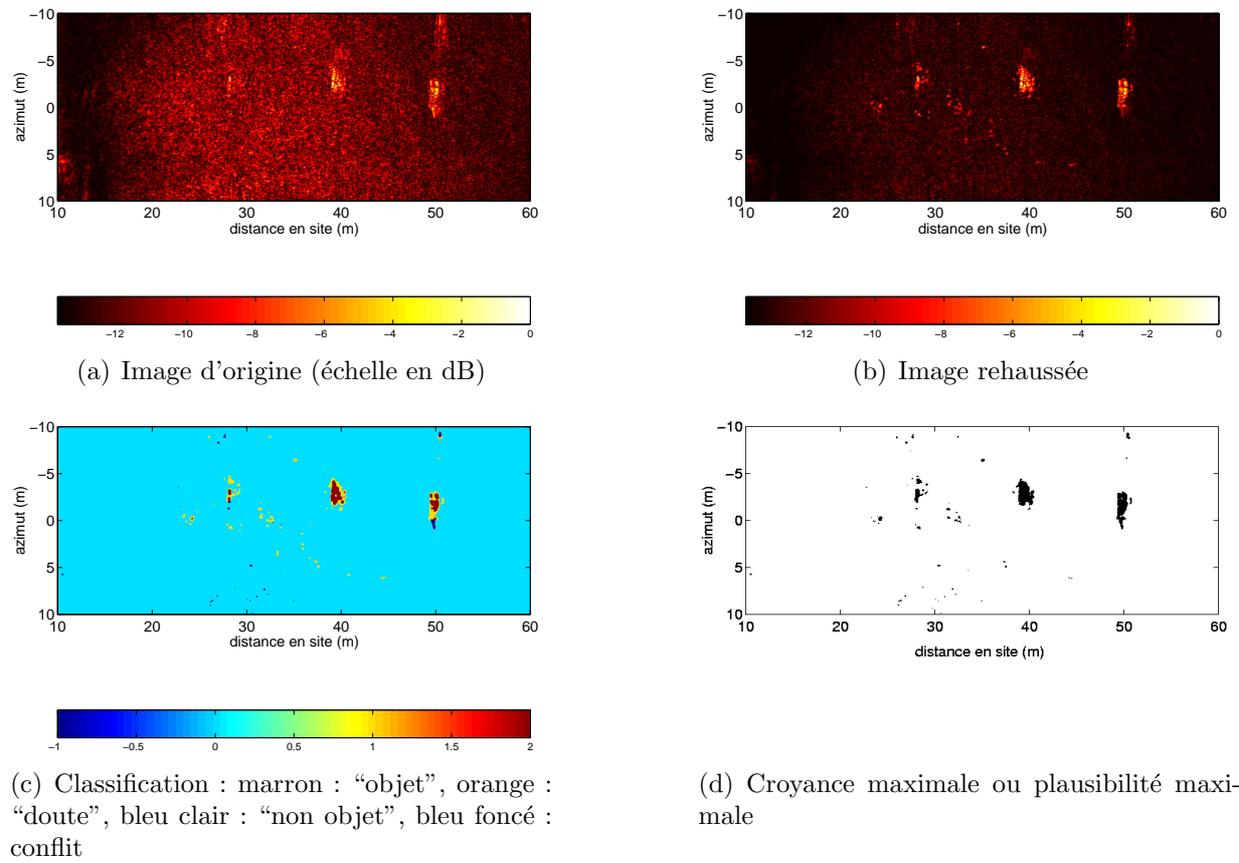


FIG. 5.23 – Présentations des résultats de la fusion sur l'image B.

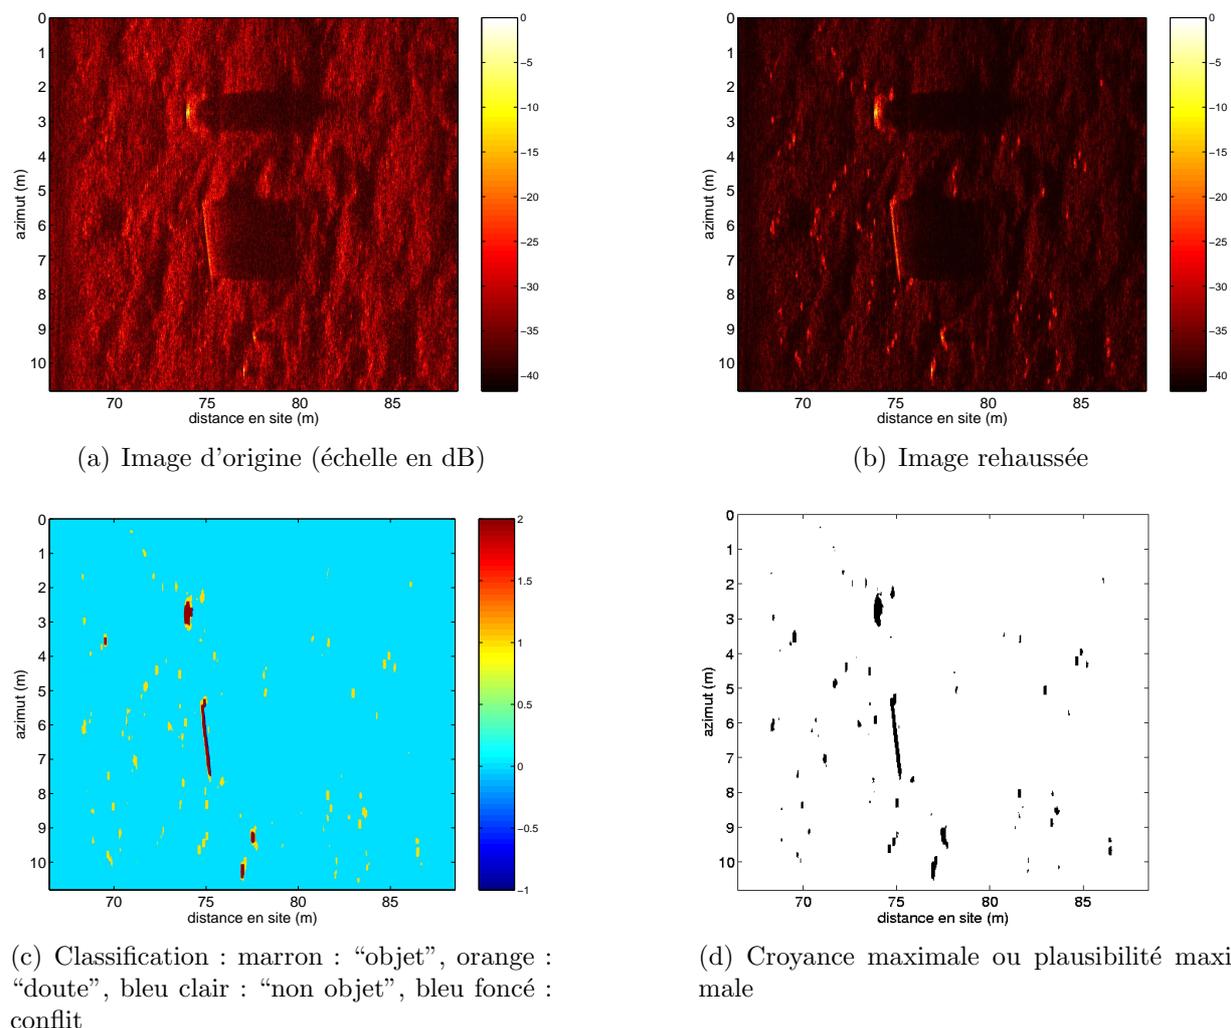


FIG. 5.24 – Présentations des résultats de la fusion sur l'image B.

### 5.4.3 Utilisation d'autres paramètres

Il est tout à fait possible de rajouter de nouveaux paramètres dans le processus de fusion, sans en modifier la structure : il s'agit seulement de le combiner avec les résultats obtenus à l'issue de la méthode proposée précédemment. De plus, il est possible d'évaluer le supplément d'information qu'il apporte, avec les grandeurs telles que la non-spécificité, ou au contraire s'il contredit les résultats précédents en mesurant le conflit.

Ces paramètres supplémentaires peuvent être de plusieurs ordres : statistiques, morphologiques, ... ou issus d'une autre image représentant la même région, une autre bande de fréquences, ...

Il semble assez difficile d'utiliser de nouveaux paramètres statistiques, suffisamment indépendants de ceux déjà utilisés, les premiers ordres statistiques décrivant déjà assez

bien les propriétés statistiques de l'image. L'utilisation de grandeurs statistiques d'ordres supérieurs à 4 rencontrerait des problèmes d'estimation.

En ce qui concerne les paramètres morphologiques, il est délicat de les combiner directement avec les autres paramètres, le raisonnement ne se faisant plus au niveau de chaque pixel, mais d'un groupe de pixels. Nous passons alors à la deuxième étape d'une structure de détection complète (voir l'introduction). En effet, jusqu'à maintenant notre problème était de savoir si un pixel appartenait ou non à un objet. Maintenant, notre objectif est d'éliminer les fausses alarmes en extrayant de nouveaux paramètres à partir des régions précédemment détectées.

Un exemple est présenté sur la figure 5.25 avec un paramètre morphologique  $\pi_m(i)$  se calculant pour chaque composante connexe  $i$  du résultat du maximum de croyance (figure 5.25(a)) à partir de sa surface  $s(i)$  et la distance euclidienne de cette composante à la composante la plus proche  $d_{\min}(i)$  :

$$\pi_m(i) = \frac{\sqrt{s(i)}}{d_{\min}(i)} \quad (5.26)$$

Ce paramètre modélise le fait qu'une région de petite taille a peu de chance d'être l'écho d'un objet s'il est très éloigné d'autres échos. Par contre, si elle est proche d'un écho, elle peut correspondre à un écho (secondaire) d'un objet. Une région de grande taille a elle de fortes chances de correspondre à un écho. Ces hypothèses sont issues d'observations sur plusieurs données SAS aux propriétés différentes. L'utilisation de ce paramètre nous donne alors une image associant à chaque composante connexe un paramètre proportionnel à la probabilité selon laquelle il correspond à un écho (figure 5.25(d)). Ce paramètre pourra être à son tour fusionné avec d'autres paramètres morphologiques, qui peuvent être plus complexes (utilisation de composantes floues en raisonnant sur les images des croyances par exemple).

Enfin, d'autres paramètres (morphologiques ou pas) et des paramètres déjà utilisés peuvent nous permettre, avec des connaissances supplémentaires, de distinguer les objets les uns des autres, "mine", "non mine" par exemple. Il est alors tout à fait possible de décomposer l'hypothèse "objet" en "mine" et "non mine" et de définir de nouvelles fonctions de masses associées à ses nouvelles hypothèses, sans modifier les fonctions existantes (les fonctions associées à la classe "non objet" ne changeraient pas, celle associée à "objet" deviendrait celle associée à "mine ou non mine" sans changer sa définition, et celle associée à la classe "doute" resterait associée au "doute" définie comme l'ensemble formé des 3 hypothèses). Cette décomposition peut continuer jusqu'au niveau de précision souhaité (et possible), sans changer le processus de fusion ("mine" pourrait se décomposer en "mine sphérique" et "mine non sphérique", etc.).

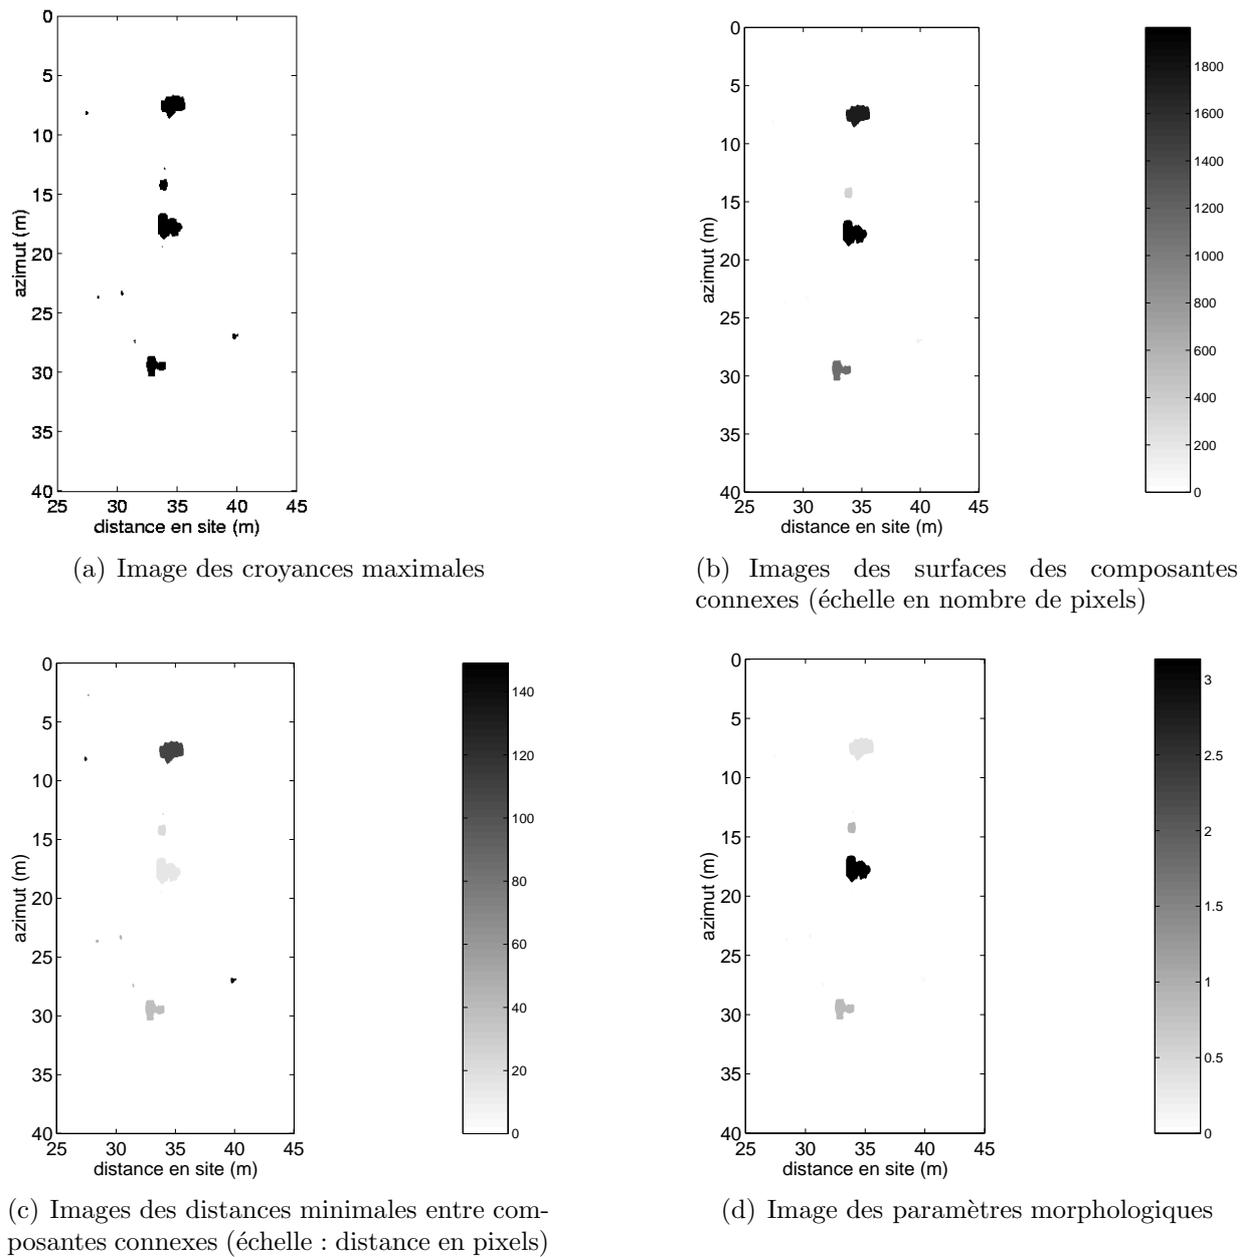


FIG. 5.25 – Exemple d'utilisation de données morphologiques dans un processus de fusion sur l'image D.

## 5.5 Conclusion

Nous avons présenté dans ce chapitre un moyen de combiner les résultats obtenus en terme de détection d'objets dans les chapitres précédents, grâce à des outils de fusion de données. En effet, la fusion nous a permis d'associer des résultats de natures et de grandeurs différentes. Le processus présenté est basé sur la théorie de l'évidence permettant de gérer

de manière efficace l'imprécis et l'incertain inhérents à nos algorithmes de détection. La fusion permet alors d'optimiser la détection des objets présents sur l'image, y compris quand ils sont enfouis dans le sédiment. La performance de cette détection a été évaluée au moyens d'outils spécifiques à la fusion (non-spécificité) ou plus généraux en détection (courbes COR), en connaissance de la vérité terrain ou pas.

La principale difficulté de ce processus a été de formater les résultats (représentation moyenne / écart-type, focalisation et reconstruction pour les ordres supérieurs) afin de pouvoir les combiner efficacement. Cependant, la souplesse de la théorie de l'évidence a permis de palier efficacement ces problèmes.

Les résultats de la fusion peuvent alors être présentés de différentes manières selon qu'ils sont destinés à un système automatisé (images binaires) ou à un expert humain (transposition à l'image d'origine).

Il est tout à fait possible d'ajouter de nouveaux paramètres (statistiques, morphologiques, etc.), issus de nouvelles connaissances ou d'autres images sonar, et de les combiner avec le résultat sans modifier la structure du processus de fusion. De plus, il sera possible d'évaluer l'information apportée par chacun d'eux.

# Conclusion et perspectives

Nous nous sommes intéressés dans cette thèse à la détection d'objets sous-marins partiellement ou totalement enfouis, à partir d'images sonar à antenne synthétique (SAS). La difficulté essentielle vient du fait de leur ensevelissement, les méthodes classiques de détection par la recherche des ombres n'étant plus applicables.

Notre approche de ce problème est alors d'étudier les paramètres susceptibles de différencier un pixel du fond bruité d'un pixel associé à un objet. Pour cela, nous avons choisi d'estimer localement, au voisinage de chacun des pixels, des paramètres statistiques d'ordres 1 et 2 (moyenne et écart-type), puis 3 et 4 (skewness et kurtosis).

Plusieurs modèles statistiques des images sonar ont été proposés dans la littérature. Parmi elles, la loi de Weibull a été choisie pour son rapport performance / complexité pour notre application. Les moments d'ordres 1 et 2, et le lien de proportionnalité existant entre eux, mis en évidence par cette loi, nous ont permis de développer un algorithme de segmentation. Celui-ci a été automatisé au moyen d'un critère d'entropie permettant de fixer le seuil automatiquement. On obtient ainsi une première segmentation assez satisfaisante, tous les objets présents étant détectés, mais avec quelques fausses alarmes.

Les moments d'ordres supérieurs (c'est à dire 3 et 4) conduisent à une autre méthode de détection efficace des échos, en évaluant localement les valeurs de grandeurs telles que le skewness (ordre 3) et le kurtosis (ordre 4). Ils fournissent ainsi des informations supplémentaires pour la détection, et en particulier celle des petits objets. Cette méthode se généralise à tout problème de détection de petits éléments (régions de petite taille, en nombre de pixels) dans un environnement bruité. Elle est particulièrement performante dans le cas d'un bruit gaussien. Ainsi, des travaux ont été réalisés dans ce sens en imagerie médicale à rayons X [CF1].

Afin d'avoir une méthode de détection plus performante, les résultats obtenus sont combinés dans un processus de fusion utilisant la théorie de l'évidence (chapitre 5). Nous nous sommes intéressés à l'évaluation de la qualité intrinsèque des résultats en déterminant la non-spécificité de la distribution de masse après fusion, et le conflit qui a pu apparaître lors de celle-ci. Il est également possible, grâce à ces valeurs numériques, de mesurer l'information supplémentaire apportée par chaque paramètre fusionné.

Tous les algorithmes ont également été testés par rapport à la vérité terrain, réalisée par expertise. Les masques ainsi construits pour matérialiser les objets ont été assez grossièrement faits, ce qui explique certaines allures de courbes COR, notamment pour la fusion. Mais elles donnent un bon aperçu des performances des algorithmes de détection

développés.

Nous avons alors proposé deux types de représentation des résultats :

- Approche décisionnelle :  $\alpha$ -coupe, maximum de plausibilité ou de croyance, classification en trois classes “écho”, “non écho” et “doute”. Ce type de représentation est plutôt destiné à un système de détection robotisé qui pourra alors considérer les groupes de pixels mis en évidence comme des régions d’intérêt.
- Approche assistance experte : transposition des résultats sur l’image d’origine par pondération des pixels ou filtrage adaptatif. Ces représentations sont destinées aux experts humains qui pourront, grâce à l’environnement de l’étude, préservé (relief, . . .), et à leurs connaissances, prendre une décision.

A la suite de ce travail de thèse, les perspectives à court terme concernent l’étude de l’influence des paramètres sur les résultats : forme de la fenêtre de calcul pour les différentes grandeurs statistiques, et en particulier aux ordres supérieurs. En effet, la détection d’un objet orienté ni horizontalement ni verticalement sur une des images sonar présentées dans ce mémoire (image B) avait soulevé quelques difficultés. Il serait alors peut-être possible de tester un algorithme adaptant la forme de la fenêtre en fonction de l’orientation des objets recherchés. Ceci pourrait s’accompagner de l’élaboration d’un algorithme plus performant de focalisation et de reconstruction (voir le chapitre 4) afin d’avoir des résultats plus nets et indépendants de l’incertitude sur la taille de l’objet, tout en tenant compte de celle-ci.

Enfin, le processus de fusion proposé dans cette thèse est évolutif dans le sens où l’on peut ajouter des paramètres ou des connaissances supplémentaires dans le schéma de fusion sans en bouleverser la structure. De plus, nous pouvons évaluer leur intérêt en mesurant la variation de conflit et de non-spécificité induite par l’ajout du paramètre. A la fin de cette thèse, nous avons abordé la détection au niveau des objets, en incluant un paramètre morphologique. Il serait intéressant, à plus long terme, de compléter ce niveau, après décision de segmentation, en ajoutant des paramètres de forme, de position, etc. On aura ainsi une décision sur le fait que les régions segmentées sont effectivement des objets ou non. Il sera alors possible d’utiliser des modèles de types d’objets (mines sphériques, . . .) afin de classifier les objets ainsi définis par ressemblance à un modèle type.

# Annexe A

## Filtrage des images sonar

Dans cette annexe est présenté un inventaire, non exhaustif, des différents filtres existants et proposés sur les images sonar. Ces filtres peuvent être appliqués en tant que prétraitement sur les images sonar afin de faciliter leur analyse (paragraphe 1.3.2.3). C’est le cas des filtres scalaires simples ou adaptés au speckle présentés ci-dessous.

Les méthodes de détection proposées dans ce mémoire utilisent les propriétés statistiques des images sonar. Nous avons alors choisi de ne pas appliquer de filtre sur les images afin de ne pas modifier ces propriétés. Nous nous intéressons plutôt au filtrage des images en “post”-traitement, c’est-à-dire afin de transposer les résultats des méthodes de détection, et en particulier de la fusion de données, sur les images originales dans le but d’aider l’expert dans sa prise de décision (paragraphe 5.4.2.2). C’est dans ce but que nous proposons à la fin de cette annexe un filtrage adaptatif des images.

### A.1 Introduction

Les différents filtres présentés dans cette annexe seront appliqués et évalués sur l’image sonar B (figure A.1(a), voir la description dans le chapitre 1).

L’évaluation des filtres s’effectue en utilisant l’image des croyances associées à la classe “objet” (figure A.1(b), voir l’obtention de cette image dans le chapitre 5). Pour cela, nous utilisons deux critères. Le premier est un rapport de variances  $k_{\mathcal{V}}$  défini par :

$$k_{\mathcal{V}} = \frac{\mathcal{V}_o}{\mathcal{V}_f} \tag{A.1}$$

avec  $\mathcal{V}_o$  la variance du fond sur l’image initiale, et  $\mathcal{V}_f$  celle sur l’image filtrée. Le fond est défini par la région ayant une croyance nulle. Ce critère mesure donc la performance du lissage effectué par le filtre : plus cette valeur est élevée, plus l’image filtrée est lissée. Le second critère évalue la préservation des échos sur l’image filtrée. Pour cela, nous utilisons la valeur  $d_{f_o}$  qui mesure la différence entre l’image initiale et l’image filtrée par :

$$d_{fo} = \frac{1}{N} \sum_{i=1}^N Cr_i(O) \cdot (x_f(i) - x_o(i))^2 \quad (\text{A.2})$$

$N$  étant la taille de l'image en pixels,  $x_o(i)$  la valeur du pixel  $i$  sur l'image d'origine,  $x_f(i)$  celle sur l'image filtrée et  $Cr_i(O)$  la croyance associée à la classe "objet" au pixel  $i$ . Plus la valeur de ce critère est faible, meilleure est la préservation des échos. Notre objectif étant de lisser au maximum le fond bruité, tout en préservant au maximum les échos, qui servent à la détection, nous rechercherons des valeurs élevées pour  $k_V$  et faibles pour  $d_{fo}$ .

Dans la suite de cette annexe,  $x(i)$  désignera la valeur du pixel  $i$  de l'image originale, contenu dans la fenêtre de filtrage composée de  $n$  pixels.  $y$  désignera la sortie du filtre, correspondant à la valeur du pixel sur l'image filtrée correspondant au centre de la fenêtre de filtrage (pixel courant).

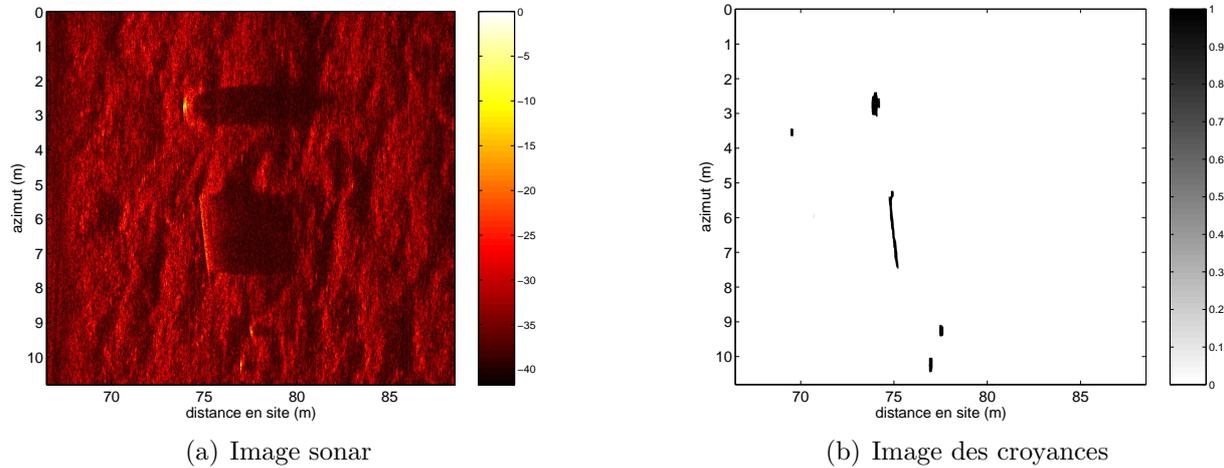


FIG. A.1 – Image sonar B et image des croyance associée.

## A.2 Filtres simples

La première catégorie de filtres présentée est celle des filtres simples. Ces filtres n'utilisent aucun *a priori* sur le bruit [CMH02].

### A.2.1 Filtre moyenneur

Le filtre le plus simple est le moyenneur qui consiste simplement à remplacer la valeur du pixel courant par la moyenne des pixels de la fenêtre :

$$y = \frac{1}{n} \sum_{i=0}^{n-1} x(i) \quad (\text{A.3})$$

La figure A.2 présente le résultat obtenu avec une fenêtre  $5 \times 5$ . On a donc une image plus lissée. Mais on perd en résolution et les échos sont largement dégradés. Ceci est confirmé par les résultats numériques consignés dans le tableau A.1. Bien entendu, plus la taille de la fenêtre de filtrage est importante, plus l'effet de flou est important.

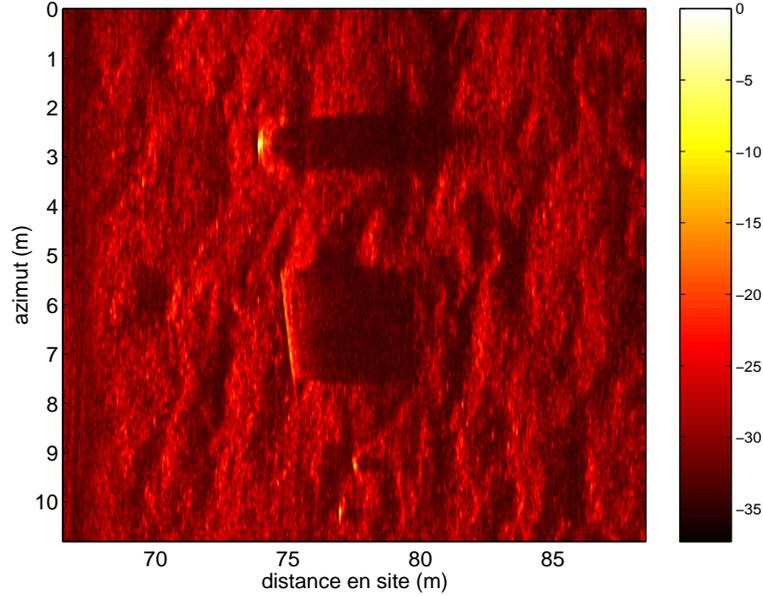


FIG. A.2 – Filtre moyennneur  $5 \times 5$ .

### A.2.2 Filtre moyennneur adaptatif

Largement utilisé en imagerie radar, le filtre moyennneur adaptatif fonctionne de la même façon que le moyennneur, mais en prenant en compte seulement les points dans la fenêtre qui n'ont pas des valeurs “aberrantes” (dont l'écart avec la valeur du pixel courant est inférieur à une valeur  $\tau$  prédéfinie). L'équation correspondante est :

$$y = \frac{1}{\sum_{i=0}^{n-1} c_i} \sum_{i=0}^{n-1} c_i x(i) \quad (\text{A.4})$$

Si l'on note  $x(0)$  la valeur du pixel courant, on a :

$$\begin{aligned} c_i &= 1 \quad \text{si} \quad |x(i) - x(0)| < \tau \\ c_i &= 0 \quad \text{sinon} \end{aligned} \quad (\text{A.5})$$

Le paramètre  $\tau$  doit avoir une valeur plus importante que l'amplitude du bruit, et plus petite que l'écart de valeur entre l'écho et le fond bruité. Si on prend une valeur trop faible, peu de pixels sont pris en compte et on s'approche du filtre identité. Par contre, si  $\tau$  est trop important, on s'approche du filtre moyennneur simple.

La figure A.3 présente le résultat obtenu avec une fenêtre  $5 \times 5$  et  $\tau = 1000$ . On obtient ainsi un lissage du fond équivalent au filtre moyennneur. Mais les valeurs des critères (tableau A.1) nous montrent une meilleure préservation des échos avec un lissage équivalent.

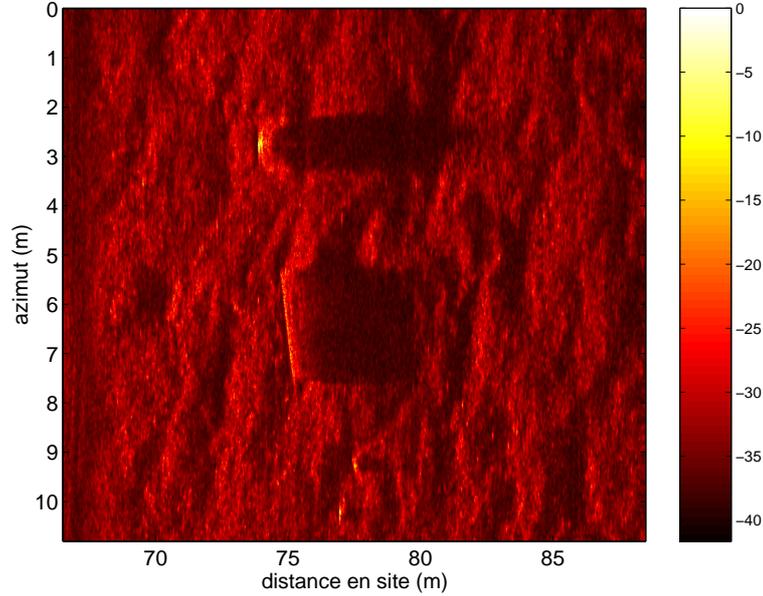


FIG. A.3 – Filtre moyennneur adaptatif  $5 \times 5$ ,  $\tau = 1000$ .

### A.2.3 Filtre à diffusion anisotrope

Le filtre à diffusion anisotrope est basé sur un processus de diffusion numérique, simulé en itérant plusieurs fois un filtre moyennneur pondéré [PM80]. Lors d'une itération, l'équation du filtre est :

$$y = \sum_{i=0}^{n-1} c_i x(i) \quad (\text{A.6})$$

En notant  $x(0)$  la valeur du pixel courant, on a :

$$\begin{aligned} c_i &= \Delta \cdot \exp \left\{ \frac{(x(i) - x(0))^2}{2\tau'^2} \right\} \quad \text{pour } i \neq 0 \\ c_0 &= 1 - \sum_{i \neq 0} c_i \end{aligned} \quad (\text{A.7})$$

Ce filtre est donc défini par quatre paramètres : le paramètre de pondération  $\Delta$ , le paramètre de diffusion  $\tau'$ , la taille de la fenêtre de calcul  $n$  et le nombre d'itérations  $n_{it}$ . Le coefficient  $\Delta$  doit être fixé en tenant compte de la taille de la fenêtre de calcul. Une bonne valeur de ce paramètre est  $\Delta = \frac{1}{2n}$ . Le coefficient  $\tau'$  a la même influence que le coefficient  $\tau$  du filtre moyennneur adaptatif. Il en est de même pour la taille de la fenêtre de calcul. Le

nombre d'itérations  $n_{it}$  influe également sur l'effet de lissage : plus le nombre d'itérations est élevé, plus le lissage est important.

La figure A.4 présente le résultat obtenu avec une fenêtre  $3 \times 3$ ,  $\Delta \approx 0,056$ ,  $\tau' = 1000$  et 20 itérations. On a un effet de lissage plus important qu'avec les deux filtres précédents, à cause de l'effet de diffusion. Mais on a une meilleure préservation des structures linéaires (relief du fond). Le tableau A.1 confirme le lissage du fond, mais nous pouvons constater une meilleure préservation des échos qu'avec un simple moyenneur, grâce à l'anisotropie, mais moins bonne qu'avec la version adaptative du moyenneur.

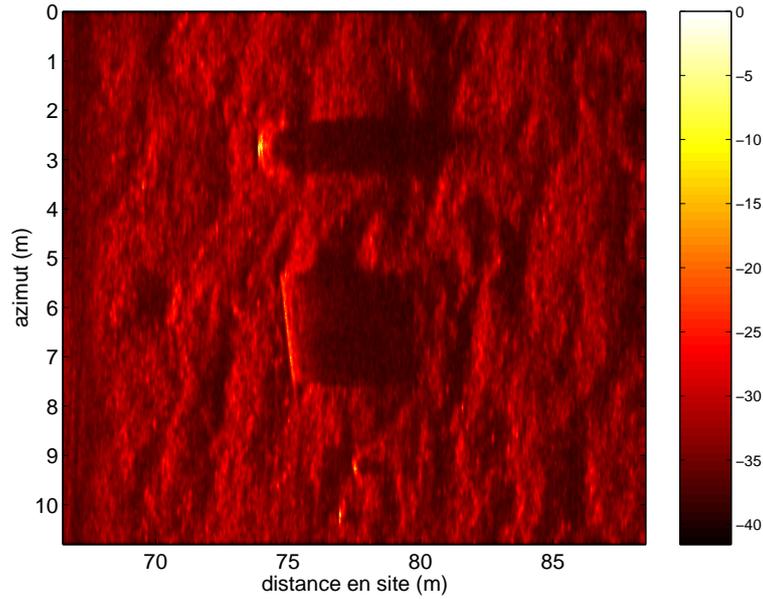


FIG. A.4 – Filtre à diffusion anisotrope  $3 \times 3$ ,  $\tau' = 1000$ , 20 itérations.

#### A.2.4 Filtre médian

Le filtre médian est un filtre non linéaire. On affecte au pixel courant la valeur médiane des valeurs des pixels contenus dans la fenêtre. L'équation vérifiée par ce filtre peut alors être formulée ainsi :

$$y = \arg \min_{z \in \{x(0) \dots x(n-1)\}} \left( \sum_{i=0}^{n-1} |z - x(i)| \right) \quad (\text{A.8})$$

Ce filtre permet d'ignorer les valeurs “aberrantes” (valeurs trop importantes ou trop faibles par rapport aux autres).

On peut remarquer sur la figure A.5 que les transitions sont bien préservées et que les points “aberrants” du fond sont supprimés. Par contre, l'effet de lissage est moins visible qu'avec les filtres précédents, ce qui est confirmé par le tableau A.1.

La valeur absolue de l'équation A.8 peut être remplacée par une puissance différente de 1, afin de favoriser le lissage du bruit (puissance supérieure à 1) ou l'effet de rehaussement des échos (puissance inférieure à 1).

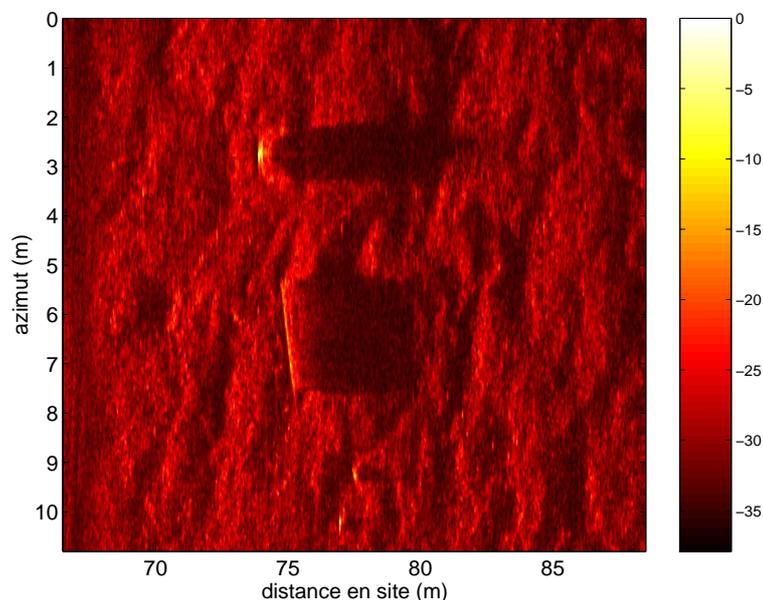


FIG. A.5 – Filtre médian  $5 \times 5$ .

TAB. A.1 – Performances des filtres simples sur l'image sonar B.

Critères	aucun filtrage	moyenneur	moyenne adapt.	anisotrope	médian
$k_{\mathcal{V}}$	1	1,82	1,70	2,22	1,71
$d_{fo}$	0	6102	105,5	1391	4458

## A.3 Filtres adaptés au speckle

Dans cette section, on fait l'hypothèse, généralement admise, que le speckle est un bruit multiplicatif  $b$  de moyenne unitaire ( $\bar{b} = 1$ ).

### A.3.1 Filtres homomorphiques

L'idée utilisée par les filtres homomorphiques est de transformer le speckle en bruit additif en passant par le logarithme. On filtre alors le résultat par un filtre scalaire simple (moyenneur par exemple) et on prend l'exponentielle du résultat [CR02]. Ces opérations ne sont pas linéaires et modifient la nature statistique du bruit. L'équation d'un filtre homomorphique avec un moyenneur est :

$$y = \exp \left\{ \frac{1}{n} \sum_{i=0}^{n-1} \log(x(i)) \right\} \quad (\text{A.9})$$

Nous obtenons alors un lissage efficace du fond bruité, mais une forte dégradation des échos (figure A.6 et tableau A.2).

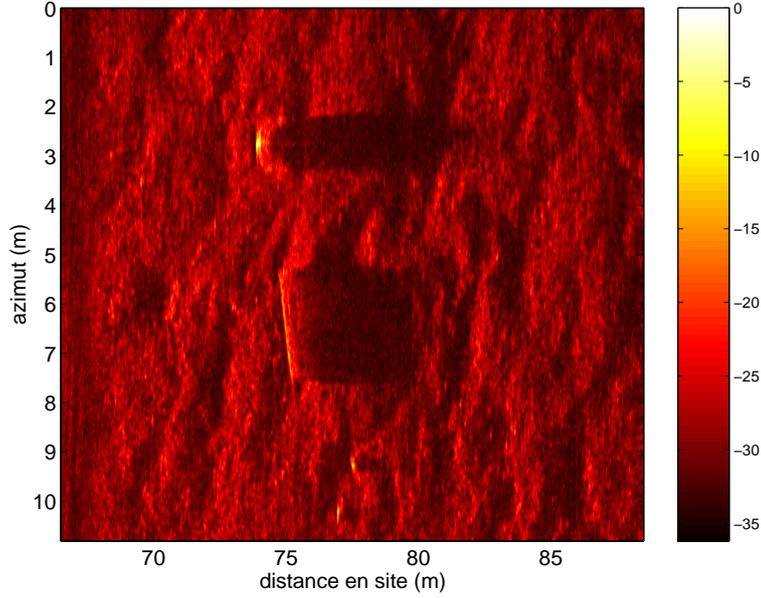


FIG. A.6 – Filtre homomorphique moyennneur  $5 \times 5$ .

### A.3.2 Filtre de Lee

Le filtre de Lee est issu de l'imagerie radar pour réduire l'effet du speckle [Lee81]. D'après les hypothèses faites au début de cette section, la valeur du pixel observé est  $x = s.b$ , où  $s$  est le signal que l'on veut récupérer. La sortie du filtre est alors :

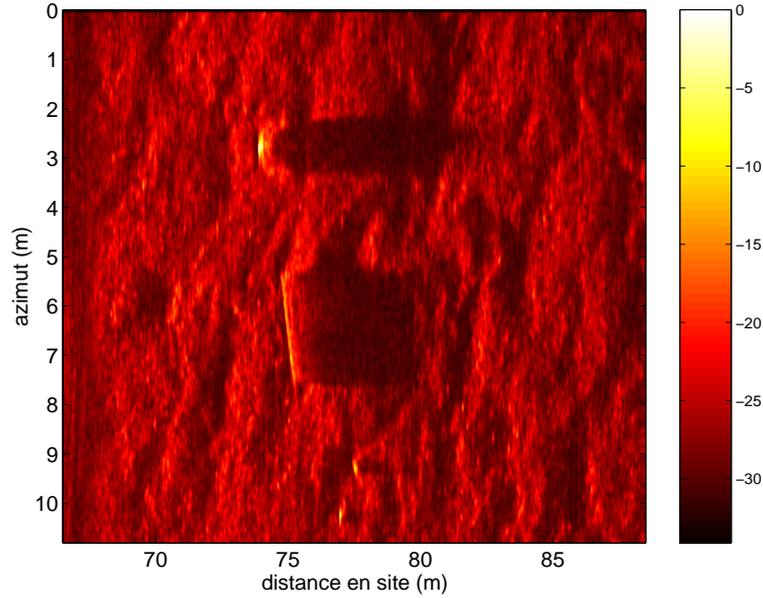
$$y = \bar{s} + k(x - \bar{s}) \quad (\text{A.10})$$

avec :

$$k = \frac{\mathcal{V}(s)}{\bar{s}^2 \mathcal{V}(b) + \mathcal{V}(s)} \quad (\text{A.11})$$

où  $\bar{s} = \frac{\bar{x}}{b} = \bar{x}$  est la moyenne du signal estimée dans la fenêtre de filtrage et  $\mathcal{V}(s) = \frac{\mathcal{V}(x) + \bar{x}^2}{\mathcal{V}(b) + 1} \bar{s}^2$  est la variance du signal estimée sur la même région.  $\mathcal{V}(b)$  est la variance du bruit évaluée sur une région du fond supposée uniforme.

Ce filtre lisse assez bien le bruit, mais dégrade fortement les échos et ne met pas en évidence les structures anisotropes (figure A.7 et tableau A.2).

FIG. A.7 – Filtre de Lee  $5 \times 5$ .

TAB. A.2 – Performances des filtres adaptés au speckle sur l’image sonar B.

Critères	aucun filtrage	moyenneur	homomorphique	Lee
$k_{\gamma}$	1	1,82	2,34	2,11
$d_{fo}$	0	6102	8375	$1,25 \cdot 10^4$

## A.4 Filtrage adaptatif

Dans cette section, nous proposons d’utiliser les connaissances que nous avons sur l’image sonar afin d’adapter les paramètres d’un filtre à la possibilité que le pixel courant soit associé à un écho, que l’on cherche à préserver, ou au fond bruité, que l’on cherche au contraire à lisser. Nous avons choisi alors d’utiliser un filtre à diffusion anisotrope, qui permet de bien lisser l’image tout en préservant les structures orientées. On va alors faire dépendre le nombre d’itérations de la croyance associée à la classe “objet”. Ainsi, pour chaque pixel de l’image sonar, nous allons faire dépendre  $n_{it}$  de la valeur de la croyance en ce pixel  $x$  :

$$n_{itx} = n_{it \max} - E\{Cr_x(O) \cdot (n_{it \max} - 1)\} \quad (\text{A.12})$$

avec  $n_{it \max}$  le nombre maximum d’itérations.  $E\{\}$  désigne la partie entière. Le nombre d’itération est alors maximal dans les régions qui ne sont pas susceptibles de contenir un objet, d’où un effet de lissage plus fort que dans les régions susceptibles de contenir un objet où le nombre d’itérations sera de 1.

Ainsi, nous obtenons un lissage important du fond bruité, équivalent à celui obtenu

avec un filtre à diffusion anisotrope simple (avec les mêmes paramètres) (figure A.8 et tableau A.3). Mais on a une meilleure préservation des échos (voir les valeurs du critère  $d_{fo}$  dans le tableau A.3 et la figure A.9). Cette préservation des échos est confirmée par les résultats obtenus sur l'image C (figure A.10). Ce type de filtrage peut alors permettre de transposer sur l'image sonar d'origine les résultats de la détection afin d'aider un expert dans son analyse de l'image.

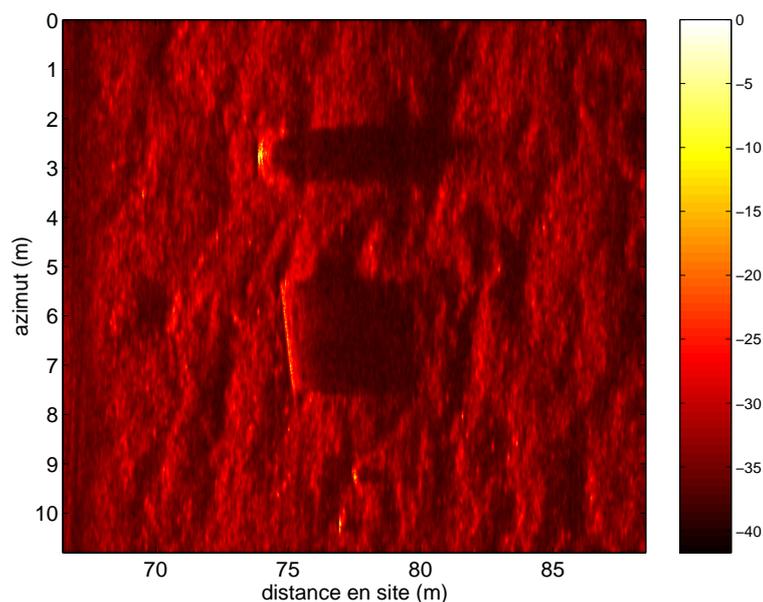


FIG. A.8 – Filtre à diffusion anisotrope adaptatif  $3 \times 3$ ,  $\tau' = 1000$ , itérations de 1 à 20.

TAB. A.3 – Performances des filtres à diffusion anisotrope.

Critères	aucun filtre	simple	adaptatif
$k_{\gamma}$	1	2,22	2,22
$d_{fo}$	0	1391	167,4

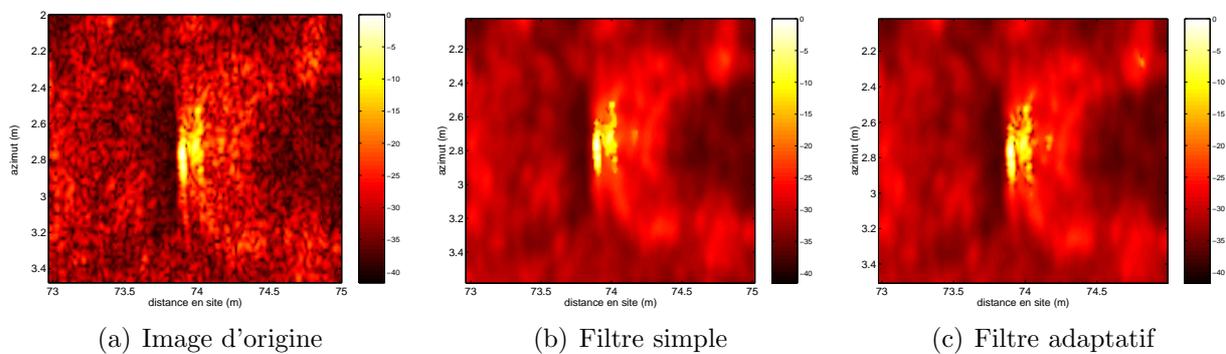


FIG. A.9 – Comparaison des échos sur les images B zoomées originale et filtrés par diffusion anisotrope.

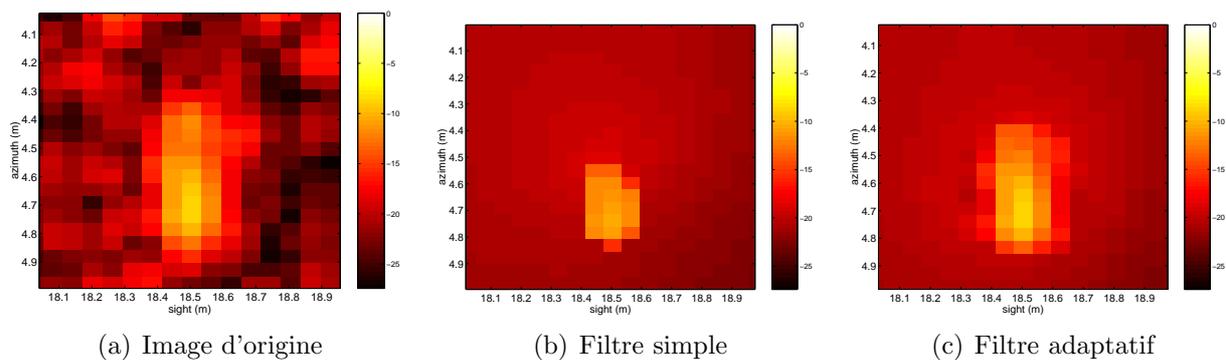


FIG. A.10 – Comparaison des échos sur les images C zoomées originale et filtrés par diffusion anisotrope  $7 \times 7$  (les autres paramètres sont identiques à ceux de l'image B).

# Liste des publications

## Conférences internationales avec actes et comité de lecture

[CI1] **F. Maussang**, M. Rombaut, J. Chanussot et A. Hétet, Fusion of Local Statistical Detectors in SAS Imagery Classification, *Proc. of IEEE/OES Oceans'05 Europe conference*, Brest, France, juin 2005.

[CI2] **F. Maussang**, J. Chanussot, S. C. Visan et M. Amate, Adaptive Anisotropic Diffusion for Speckle Filtering in SAS Imagery, *Proc. of IEEE/OES Oceans'05 Europe conference*, Brest, France, juin 2005.

[CI3] M. Amate, A. Hétet, S. Guyonic, M. Legris, R. Bellec, **F. Maussang**, J. Chanussot, P. Cervenka et J. Marchal, Buried mines detection and classification : advanced technologies and signal processing, *Proc. of IEEE/OES Oceans'05 Europe conference*, Brest, France, juin 2005.

[CI4] **F. Maussang**, J. Chanussot et A. Hétet, Higher Order Statistics for the Detection of Underwater Mines in SAS Imagery, *Proc. of the 7th European Conference on Underwater Acoustics (ECUA'04)*, Delft, Pays-Bas, juillet 2004, pp. 1115 - 1120.

[CI5] **F. Maussang**, J. Chanussot et A. Hétet, On the Use of Higher Order Statistics in SAS Imagery, *Proc. of IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP'04)*, Montréal, Québec, Canada, mai 2004, vol. 5, pp. 269 - 272.

[CI6] **F. Maussang**, J. Chanussot et A. Hétet, Automated Segmentation of SAS Images using the Mean - Standard Deviation Representation, *Proc. of MTS/IEEE Oceans'03 conference*, San Diego, Californie, USA, septembre 2003, pp. 2155 - 2160.

[CI7] **F. Maussang**, J. Chanussot et A. Hétet, Synthetic Aperture Sonar Imagery : towards a Classification of Underwater Mines in the Mean - Standard Deviation Plane, *Proc. of Physics in Signal and Image Processing, PSIP'03*, Grenoble, France, janvier 2003, pp. 137 - 140.

[CI8] J. Chanussot, **F. Maussang**, and A. Hétet, Scalar Image Processing Filters for Speckle Reduction on Synthetic Aperture Sonar Images, *Proc. of MTS/IEEE Oceans'02 conference*, Biloxi, Mississippi, USA, octobre 2002, pp. 2294 - 2301.

## Conférences francophones avec actes et comité de lecture

[CF1] **F. Maussang** et J. Chanussot, Utilisation des statistiques d'ordre supérieur en contrôle qualité de détecteurs de rayons X, *Actes du 20e colloque GRETSI*, Louvain-la-Neuve, Belgique, septembre 2005, pp. 117 - 120.

[CF2] **F. Maussang**, M. Rombaut, J. Chanussot, A. Hétet et M. Amate, Fusion de données statistiques locales pour la détection en imagerie SAS, *Actes des 12e rencontres francophones sur la Logique Floue et ses Applications (LFA'04)*, Nantes, France, novembre 2004, pp. 189 - 196.

[CF3] **F. Maussang**, M. Rombaut et J. Chanussot, Détection en Imagerie SAS par Fusion de Données de Statistiques Locales, *Actes des 7e Journées d'Acoustique Sous-Marine (JASM'04)*, Brest, France, octobre 2004, pp. 185 - 194.

[CF4] **F. Maussang**, J. Chanussot et A. Hétet, Segmentation automatique d'images sonar à antenne synthétique pour la détection d'échos de mines sous-marines, *Actes du 19e colloque GRETSI*, Paris, France, septembre 2003, vol. 3, pp. 284 - 287.

## Articles soumis à des revues internationales avec comité de lecture

[R1] **F. Maussang**, J. Chanussot, A. Hétet et M. Amate, Higher Order Statistics for the Detection of Small Objects in a Noisy Background, Application in Sonar Imagery, soumis à *IEEE Transactions on Signal Processing*.

[R2] **F. Maussang**, J. Chanussot, A. Hétet et M. Amate, Mean / Standard Deviation Representation of Sonar Images for Echo Detection, Application to SAS Images, soumis à *IEEE Journal of Oceanic Engineering*, en cours de révisions.

# Bibliographie

- [ACRKRA<sup>+</sup>05] C. Avilés-Cruz, R. Rangel-Kuoppa, M. Reyes-Ayala, A. Andrade-Gonzalez et R. Escarela-Perez. High-order statistical texture analysis – font recognition applied. *Pattern Recognition Letters*, 26(2) :135 – 145, janvier 2005.
- [AFD97] T. Aridgides, M. Fernández et G. Dobeck. Adaptive 3-dimensional range-crossrange-frequency filter processing string for sea mine classification in side-scan sonar imagery. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets II*, volume 3079, pages 111 – 122, Orlando, Floride, USA, avril 1997.
- [AFD01] T. Aridgides, M. Fernández et G. Dobeck. Side scan sonar imagery fusion for sea mine detection and classification in very shallow water. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VI*, volume 4394, pages 1123 – 1134, Orlando, Floride, USA, avril 2001.
- [AFD03a] T. Aridgides, M. Fernández et G. Dobeck. Processing string fusion approach investigation for automated sea mine classification in shallow water. In *Proc. of Oceans'03 conference*, pages 1111 – 1118, San Diego, Californie, USA, septembre 2003.
- [AFD03b] T. Aridgides, M. Fernández et G. J. Dobeck. Recent processing string and fusion algorithm improvements for automated sea mine classification in shallow water. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VIII*, volume 5089, pages 65 – 76, Orlando, Floride, USA, avril 2003.
- [AL04] D. A. Abraham et A. P. Lyons. Guest editorial : non-Rayleigh reverberation and clutter. *IEEE Journal of Oceanic Engineering*, 29(2) :193 – 196, avril 2004.
- [ALFD96] T. Aridgides, P. Libera, M. Fernández et G. Dobeck. Adaptive filter / feature orthogonalization processing string for optimal LLRT mine classification in side-scan sonar imagery. In *Proc. of SPIE*, volume 2765, pages 110 – 121, Orlando, Floride, USA, avril 1996.
- [BCIL99] P. Bolon, J. Chanussot, I. Issa et P. Lambert. Comparison of prefiltering operators for road network extraction in SAR images. In *Proc. of IEEE*

- International Conference on Image Processing, ICIP'99*, pages 924 – 928, Kobe, Japon, octobre 1999.
- [BG01] S. Batman et J. Goutsias. Robust morphological detection of sea mines in side-scan sonar images. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VI*, volume 4394, pages 1103 – 1115, Orlando, Floride, USA, avril 2001.
- [Blo95] I. Bloch. *Fusion de données, ensembles flous et morphologie mathématique en traitement d'images. Application à l'imagerie médicale cérébrale et cardio-vasculaire multi-modalités*. Partie scientifique du rapport d'habilitation à diriger des recherches, Ecole Nationale Supérieure des Télécommunications, Paris, France, avril 1995.
- [Blo96] I. Bloch. Incertitude, imprécision et additivité en fusion de données : point de vue historique. *Traitement du Signal*, 13(4) :267 – 288, 1996.
- [Blo03] I. Bloch. *Fusion numérique d'informations en traitement du signal et des images*. Hermes Science Publication, collection IC2, Paris, France, 2003. ISBN 2-7462-0628-5.
- [Bou92] M. Bouvet. *Traitement des Signaux pour les Systèmes Sonar*. Collection Technique et Scientifique des Télécommunications, Masson, Paris, France, 1992.
- [CBZ92] J. Chatillon, M.-E. Bouhier et M. E. Zakharia. Synthetic aperture sonar for seabed imaging : relative merits of narrow-band and wide-band approaches. *IEEE Journal of Oceanic Engineering*, 17(1) :95 – 105, janvier 1992.
- [CHMT02] J. Chanussot, A. Hétet, G. Le Merrer et E. Tireau. Multispectral decomposition of synthetic aperture sonar images for speckle reduction. In *Proc. of the 6th European Conference on Underwater Acoustics, ECUA 2002*, Gdansk, Pologne, juin 2002.
- [CJD94] C. Coroyer, C. Jorand et P. Duvaut. ROC curves of skewness and kurtosis statistical tests : Application to textures. In *Proc. of the 7th European Signal Processing Conference (EUSIPCO'94)*, volume 1, pages 450 – 453, Edimbourg, Ecosse, Royaume-Uni, septembre 1994.
- [CMH02] J. Chanussot, F. Maussang et A. Hétet. Scalar image processing filters for speckle reduction on synthetic aperture sonar images. In *Proc. of MTS/IEEE Oceans'02 conference*, pages 2294 – 2301, Biloxi, Mississippi, USA, octobre 2002.
- [CR93] S. Carrato et G. Ramponi. Edge detection using generalized higher-order statistics. In *Proc. of the IEEE Signal Processing Workshop on Higher-Order Statistics*, pages 66 – 70, South Lake Tahoe, Californie, USA, juin 1993.

- [CR02] D. Coltuc et R. Radescu. On the homomorphic filtering by chanell's summation. In *Proc. of IEEE International Geoscience and Remote Sensing Symposium, IGARSS'02*, Toronto, Ontario, Canada, juin 2002.
- [CRB05] P.-J. Chung, W. J. J. Roberts et J. F. Böhme. Recursive K-distribution parameter estimation. *IEEE Transactions on Signal Processing*, 53(2) :397 – 402, février 2005.
- [CTM<sup>+</sup>98] C. Collet, P. Thourel, M. Mignotte, P. Pérez et P. Bouthemy. Segmentation markovienne hiérarchique multimodèle d'images sonar haute résolution. *Traitement du Signal*, 15(3) :231 – 250, octobre 1998.
- [DC02] G. J. Dobeck et J. T. Cobb. Fusion of multiple quadratic penalty function support vector machines (qpfsvm) for automated sea mine detection and classification. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VII*, volume 4742, pages 401 – 411, Orlando, Floride, USA, avril 2002.
- [Dob01] G. J. Dobeck. On the power of algorithm fusion. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VI*, volume 4394, pages 1092 – 1102, Orlando, Floride, USA, avril 2001.
- [Faw03] J. A. Fawcett. Computer-aided detection and classification of minelike objects using template-based features. In *Proc. of MTS/IEEE Oceans'03 conference*, pages 1395 – 1401, San Diego, Californie, USA, septembre 2003.
- [FMRT97] G. L. Foresti, V. Murino, C. S. Regazzoni et A. Trucco. A voting-based approach for fast object recognition in underwater acoustic images. *IEEE Journal of Oceanic Engineering*, 22(1) :57 – 65, janvier 1997.
- [GA01] M. Gu et D. A. Abraham. Using McDaniel's model to represent non-Rayleigh reverberation. *IEEE Journal of Oceanic Engineering*, 26(3) :348 – 357, juillet 2001.
- [Goo76] J. W. Goodman. Some fundamental properties of speckle. *Journal of Optical Society of America*, 66(11) :1145 – 1150, novembre 1976.
- [Haw96] D. W. Hawkins. *Synthetic Aperture Imaging Algorithms : with application to wide bandwidth sonar*. Ph. d. thesis, University of Canterbury, Christchurch, Nouvelle-Zélande, octobre 1996.
- [HAZ<sup>+</sup>04] A. Hétet, M. Amate, B. Zerr, M. Legris, R. Bellec, J. C. Sabel et J. Groen. SAS processing results for the detection of buried objects with a ship-mounted sonar. In *Proc. of the Seventh European Conference on Underwater Acoustics, ECUA 2004*, pages 1127 – 1132, Delft, Pays-Bas, juillet 2004.
- [HBL03] L. Hellequin, J.-M. Boucher et X. Lurton. Processing of high-frequency multibeam echo sounder data for seafloor characterization. *IEEE Journal of Oceanic Engineering*, 28(1) :78 – 89, janvier 2003.

- [HD95] J. C. Hyland et G. J. Dobeck. Sea mine detection and classification using side-looking sonar. In *Proc. of SPIE, Detection Technologies for Mines and Minelike Targets*, volume 2496, pages 442 – 453, Orlando, Floride, USA, avril 1995.
- [Hel98] L. Hellequin. *Analyse statistique et spectrale des signaux de sondeurs multifaisceaux EM950. Application à l'identification des fonds sous-marins*. Thèse de doctorat, Université de Rennes 1, Rennes, France, décembre 1998.
- [HG04] M. P. Hayes et P. T. Gough. Synthetic aperture sonar : a maturing discipline. In *Proc. of the Seventh European Conference on Underwater Acoustics, ECUA 2004*, pages 1101 – 1106, Delft, Pays-Bas, juillet 2004.
- [HKHC03] A. Hanssen, J. Kongsli, R. E. Hansen et S. Chapman. Statistics of synthetic aperture sonar images. In *Proc. of MTS/IEEE Oceans'03 conference*, pages 2635 – 2640, San Diego, Californie, USA, septembre 2003.
- [HMC02] C. Hory, N. Martin et A. Chehikian. Spectrogram segmentation by means of statistical features for non-stationary signal interpretation. *IEEE Transactions on Signal Processing*, 50(12) :2915 – 2925, décembre 2002.
- [Hor02] C. Hory. *Mélanges de distributions du  $\chi^2$  pour l'interprétation d'une représentation temps-fréquence*. Thèse de doctorat, Institut National Polytechnique de Grenoble, Grenoble, France, décembre 2002.
- [Hét00] A. P. Hétet. Evaluation of specific aspects of synthetic aperture sonar, by conducting at sea experiments with a rail, in the frame of mine hunting systems design. In *Proc. of the Fifth European Conference on Underwater Acoustics, ECUA 2000*, pages 439 – 444, Lyon, France, juillet 2000.
- [Hét03] A. Hétet. *Contribution à la détection de mines enfouies dans le sédiment marin par synthèse d'ouverture basse fréquence*. Thèse de doctorat, Université Paris 6, Brest, France, juillet 2003.
- [IZ99] D. R. Iskander et A. M. Zoubir. Estimation of the parameters of the K-distribution using higher order and fractional moments. *IEEE Transactions on Aerospace Electronic Systems*, 35(4) :1453 – 1457, octobre 1999.
- [IZB99] D. R. Iskander, A. M. Zoubir et B. Boashash. A method for estimating the parameters of the K distribution. *IEEE Transactions on Signal Processing*, 47(4) :1147 – 1151, avril 1999.
- [Jac91] G. Jacovitti. Applications of higher order statistics in image processing. In *Proc. of the International Signal Processing workshop on Higher Order Statistics*, pages 241 – 247, Chamrousse, France, juillet 1991.
- [JD94] S. G. Johnson et M. A. Deaett. The application of automated recognition techniques to side-scan sonar imagery. *IEEE Journal of Oceanic Engineering*, 19(1) :138 – 144, janvier 1994.
- [JPW93] I. R. Joughin, D. B. Percival et D. P. Winebrenner. Maximum likelihood estimation of K ditribution parameters for SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 31(5) :989 – 999, septembre 1993.

- [Kes02] R. T. Kessel. Using sonar speckle to identify regions of interest and for mine detection. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VII*, volume 4742, pages 440 – 451, Orlando, Floride, USA, avril 2002.
- [KS63] M. G. Kendall et A. Stuart. *The Advanced Theory of Statistics*, volume 1. Charles Griffin & Company Limited, Londres, Royaume-Uni, 2nd edition, 1963.
- [KW99] G. J. Klir et M. J. Wierman. *Uncertainty-Based Information*. Physica-Verlag Heidelberg, New York, USA, 1999.
- [LAC97] J.-L. Lacoume, P.-O. Amblard et P. Comon. *Statistiques d'Ordre Supérieur pour le Traitement du Signal*. Masson, Paris, France, 1997. ISBN 2-225-8318-1, [http://www.lis.inpg.fr/pages\\_perso/bidou/livreSOS.html](http://www.lis.inpg.fr/pages_perso/bidou/livreSOS.html).
- [Lee81] J. S. Lee. Speckle analysis and smoothing of synthetic aperture radar images. *Computer Graphics and Image Processing*, 17 :24 – 31, 1981.
- [LLF04] F. Luthon, M. Liévin et F. Faux. On the use of entropy power for threshold selection. *Signal Processing*, 84(10) :1789 – 1804, octobre 2004.
- [LLFZ03] M. Legris, K. Lebart, F. Fohanno et B. Zerr. Les capteurs d'imagerie en robotique sous-marine : tendances actuelles et futures. *Traitement du Signal*, 20(2) :137 – 164, septembre 2003.
- [LS94] D. M. Lane et J. P. Stoner. Automatic interpretation of sonar imagery using qualitative feature matching. *IEEE Journal of Oceanic Engineering*, 19(3) :391 – 405, juillet 1994.
- [Lur02] X. Lurton. *Éléments d'analyse des systèmes acoustiques sous-marins*. EN-SIETA, Brest, France, 2002. Polycopié de cours de 3e année.
- [McD90] S. T. McDaniel. Seafloor reverberation fluctuations. *Journal of Acoustical Society of America*, 88(3) :1530 – 1535, septembre 1990.
- [MCPB97] M. Mignotte, C. Collet, P. Pérez et P. Bouthemy. Unsupervised markovian segmentation of sonar images. In *22nd IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP'97*, volume 4, pages 2781 – 2785, Munich, Allemagne, mai 1997.
- [MCPB98] M. Mignotte, C. Collet, P. Pérez et P. Bouthemy. Statistical model and genetic optimization : Application to pattern detection in sonar images. In *23rd IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP'98*, volume 5, pages 2741 – 2745, Seattle, Washington, USA, mai 1998.
- [MCPB99] M. Mignotte, C. Collet, P. Pérez et P. Bouthemy. Three-class markovian segmentation of high-resolution sonar images. *Computer Vision and Image Understanding*, 76(3) :191 – 204, décembre 1999.

- [MCPB00] M. Mignotte, C. Collet, P. Pérez et 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*, 22(2) :129 – 141, février 2000.
- [Mig98] M. Mignotte. *Segmentation d'images sonar par approche markovienne hiérarchique non supervisée et classification d'ombres portées par modèles statistiques*. Thèse de doctorat, Université de Bretagne Occidentale, Brest, France, juillet 1998.
- [Mil01] N. Milisavljević. *Analyse et fusion par la théorie des fonctions de croyances de données multi-sensorielles pour la détection de mines anti-personnelles*. Thèse de doctorat, Ecole Nationale Supérieure des Télécommunications, Paris, France, mars 2001.
- [MvdBB<sup>+</sup>01] N. Milisavljević, S. P. van den Broek, I. Bloch, P. B. W. Schwing, H. A. Lensen et M. Acheroy. Comparison of belief functions and voting method for fusion of mine detection sensors. In *Proc. of SPIE, Detection and Remediation Technologies for Mines and Minelike Targets VI*, volume 4394, pages 1011 – 1022, Orlando, Floride, USA, avril 2001.
- [Nic02] J.-M. Nicolas. *Introduction aux statistiques de deuxième espèce : Application aux lois d'images RSO*. Ecole Nationale Supérieure des Télécommunications, Paris, France, février 2002.
- [Nic03] J.-M. Nicolas. La loi de Fisher et ses applications aux images de radar à synthèse d'ouverture. In *Actes du 19e colloque GRETSI'03*, pages 209 – 212, Paris, France, septembre 2003.
- [Oll95] F. Ollivier. *Conception et réalisation d'un sonar latéral bathymétrique à haute résolution avec voies préformées compensées en altitude*. Thèse de doctorat, Université Paris 6, Paris, France, avril 1995.
- [PG04] S. W. Perry et L. Guan. Pulse-length-tolerant features and detectors for sector-scan sonar imagery. *IEEE Journal of Oceanic Engineering*, 29(1) :138 – 156, janvier 2004.
- [PM80] P. Perona et J. Malik. Scale-space and edge detection using anisotropic diffusion. *IEEE transactions on Pattern Analysis and Machine Intelligence*, 2(7) :629 – 639, 1980.
- [Pun80] T. Pun. A new method for grey-level picture thresholding using the entropy of the histogram. *Signal Processing*, 2(3) :223 – 237, juillet 1980.
- [Pun81] T. Pun. Entropic thresholding, a new approach. *Computer Graphics and Image Understanding*, 16 :210 – 239, 1981.
- [QBMF05] I. Quidu, N. Burlet, J.-P. Malkasse et F. Florin. Automatic classification for MCM systems. In *Proc. of IEEE/OES Oceans'05 Europe conference*, Brest, France, juin 2005.

- [QMB03] I. Quidu, J. P. Malkasse et G. Burel. Classification de mines sous-marines à partir de l'image sonar brute : caractérisation du contour de l'ombre par algorithme génétique. *Traitement du Signal*, 20(1) :55 – 76, juillet 2003.
- [RC94] G. Ramponi et S. Carrato. Performance of the skewness-of-gaussian (sog) edge extractor. In *Proc. of the 7th European Signal Processing Conference (EUSIPCO'94)*, volume 1, pages 454 – 457, Edimbourg, Ecosse, Royaume-Uni, septembre 1994.
- [RJD99] A. N. Rajagopalan, A. Jain et U. B. Desai. Data clustering using hierarchical deterministic annealing and higher order statistics. *IEEE Transactions on Circuits and Systems – II : Analog and Digital Signal Processing*, 46(8) :1100 – 1104, août 1999.
- [Rom01] M. Rombaut. *Fusion : état de l'art et perspectives*. Convention DSP 99.60.078, Troyes, France, octobre 2001.
- [RPB03] S. Reed, Y. Petillot et J. Bell. An automatic approach to the detection and extraction of mine features in sidescan sonar. *IEEE Journal of Oceanic Engineering*, 28(1) :90 – 105, janvier 2003.
- [RPB04] S. Reed, Y. Petillot et J. Bell. Model-based approach to the detection and classification of mines in sidescan sonar. *Applied Optics*, 43(2) :237 – 246, janvier 2004.
- [Sap90] G. Saporta. *Probabilités. Analyse des données et statistique*. Technip, Paris, France, 1990.
- [SGC<sup>+</sup>04] J. C. Sabel, J. Groen, M. E. G. D. Colin, B. A. J. Quesson, A. Hétet, B. Zerr, M. Brussieux et M. Legris. Experiments with a ship-mounted low frequency sas for the detection of buried objects. In *Proc. of the Seventh European Conference on Underwater Acoustics, ECUA 2004*, pages 1133 – 1138, Delft, Pays-Bas, juillet 2004.
- [Sha76] G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, 1976.
- [SMCT96] F. Schmitt, M. Mignotte, C. Collet et P. Thourel. Estimation of noise parameters on sonar images. In *Proc. of SPIE conference on Signal and Image Processing*, volume 2823, pages 1 – 12, Denver, Colorado, USA, août 1996.
- [Sme90] P. Smets. The combination of evidence in the transferable belief model. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(5) :447 – 458, 1990.
- [Sme00] P. Smets. Data fusion in the transferable belief model. In *Proc. of the 3rd International Conference on Information Fusion*, pages 21 – 33, Paris, France, 2000.
- [Spe90] Special issue on higher-order statistics. *IEEE Journal of Acoustics, Speech, and Signal Processing*, 38(7), juillet 1990.

- [Spe94] Special issue on higher-order statistics. *Signal Processing*, 36(3), avril 1994.
- [Spe96] Special issue on higher-order statistics. *Signal Processing*, 53(2-3), septembre 1996.
- [TNTM04] C. Tison, J.-M. Nicolas, F. Tupin et H. Maître. A new statistical model for markovian classification of urban areas in high-resolution SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 42(10) :2046 – 2057, octobre 2004.
- [Val01] L. Valet. *Un système flou de fusion coopérative : application au traitement d'images naturelles*. Thèse de doctorat, Université de Savoie, Chambéry, France, décembre 2001.
- [YMC<sup>+</sup>00] K. C. Yao, M. Mignotte, C. Collet, P. Galerne et G. Burel. Unsupervised segmentation using a self-organizing map and a noise model estimation in sonar imagery. *Pattern Recognition*, 33(9) :1575 – 1584, septembre 2000.
- [Zad65] L. A. Zadeh. Fuzzy sets. *Information and Control*, 8 :338 – 353, 1965.

# Table des figures

1.1	Quelques applications civiles de l'acoustique sous-marine. . . . .	13
1.2	Quelques applications militaires de l'acoustique sous-marine. . . . .	14
1.3	Exemples d'objets servant de modèles de mines sous-marines de fond. . . . .	16
1.4	Principe de la détection d'objets sur les images sonar. . . . .	23
1.5	Principe de la classification sur ombre. . . . .	24
1.6	Images d'un sonar utilisé comme SAS. . . . .	26
1.7	Principe du sonar à antenne synthétique. . . . .	27
1.8	Principe de la synthèse d'ouverture. . . . .	28
1.9	Exemple de formation d'une image SAS (échelle en dB, coordonnées en pixels). . . . .	28
1.10	Images SAS haute résolution. . . . .	31
1.11	Image SAS basse résolution : image C. . . . .	31
1.12	Images SAS basse résolution. . . . .	32
2.1	Lois de Rayleigh pour différentes valeurs du paramètre $\alpha$ . . . . .	37
2.2	Lois de Weibull pour différentes valeurs du paramètre $\delta$ ( $\beta = 0,5$ ). . . . .	39
2.3	Variation de l'estimation du paramètre $\delta$ de la loi de Weibull en fonction du nombre d'itérations. . . . .	41
2.4	Modèles estimés sur l'image A. . . . .	48
2.5	Modèles estimés sur l'image C. . . . .	49
2.6	Modèles estimés sur l'image D. . . . .	50
3.1	Modèle d'un écho et différentes valeurs du paramètre $p$ : . . . . .	54
3.2	Moyenne en fonction de l'écart-type des valeurs des pixels d'une fenêtre pour différents RSB ( $\sigma_B = 1$ , $k = k_R \approx 1,91$ ). . . . .	56
3.3	Construction d'une représentation moyenne / écart-type. . . . .	57
3.4	Représentation moyenne / écart-type d'une partie de l'image A. . . . .	57
3.5	Représentation moyenne / écart-type d'une partie de l'image A. . . . .	59
3.6	Interprétation d'une représentation moyenne / écart-type. . . . .	60
3.7	Comparaison entre l'image sonar et sa représentation moyenne / écart-type. . . . .	61
3.8	Segmentation d'une image sonar (seuils : écart-type = 4000 ; moyenne = 6751). . . . .	62
3.9	Résultats de la segmentation pour différents seuils en écart-type. . . . .	63
3.10	Image sonar segmentée et répartition des pixels segmentés selon les deux axes. . . . .	64

3.11	Variation des entropies selon les deux axes en fonction du seuil en écart-type.	65
3.12	Choix du seuil à partir du critère d'entropie et de sa dérivée (seuil choisi : voir le flèche).	66
3.13	Evaluation de la probabilité de détection et du taux de fausse alarme.	67
3.14	Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image C (chapitre 1).	70
3.15	Résultats de la segmentation automatique et d'un simple seuillage sur l'image C.	71
3.16	Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image D (chapitre 1).	72
3.17	Résultats de la segmentation automatique et d'un simple seuillage sur l'image D.	73
3.18	Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image E (chapitre 1).	74
3.19	Résultats de la segmentation automatique et d'un simple seuillage sur l'image E.	75
3.20	Comparaison des performances de la méthode de segmentation proposée et du simple seuillage sur l'image B (chapitre 1).	76
3.21	Résultats de la segmentation automatique et d'un simple seuillage sur l'image B.	77
3.22	Schéma synthétique de la méthode de détection proposée : la segmentation automatique.	79
4.1	Valeurs des skewness et kurtosis en fonction de la proportion de pixels déterministes $p$ et du RSB.	90
4.2	Valeurs des skewness et kurtosis en fonction du RSB pour des valeurs de $p$ faibles (trait continu) ou élevées (traits pointillés).	90
4.3	Skewness (traits pointillés) et kurtosis (trait continu) en fonction du paramètre $p$ pour un RSB de -60dB.	91
4.4	Exemple de densité de probabilité sur une fenêtre de calcul pour un RSB faible ( $p = 0, 4$ ).	92
4.5	Images des SOS évaluées sur une fenêtre $21 \times 21$ .	92
4.6	Images des kurtosis obtenues pour différentes tailles de fenêtres (RSB = -60dB).	93
4.7	Skewness (traits pointillés) et kurtosis (trait continu) en fonction du paramètre $p$ pour un RSB de 50dB.	95
4.8	Images des SOS évaluées sur une fenêtre $21 \times 21$ .	95
4.9	Images des kurtosis obtenues pour différentes tailles de fenêtre (RSB = 50dB).	97
4.10	Zoom sur les images des SOS obtenues pour une fenêtre $13 \times 13$ (RSB = 50dB).	97
4.11	Images des kurtosis obtenues pour différentes tailles de fenêtre sur une image contenant deux régions déterministes (RSB = 70dB à gauche, RSB = 50dB à droite).	98

4.12	Images des SOS évaluées sur une fenêtre $13 \times 13$ . . . . .	99
4.13	Images des SOS évalués sur une fenêtre $21 \times 21$ . . . . .	100
4.14	Modèle théorique du kurtosis utilisé pour le filtre adapté (fenêtre $31 \times 31$ , région déterministe $11 \times 11$ ). . . . .	102
4.15	Focalisation par filtrage adapté sur l'image des kurtosis (fenêtre $21 \times 21$ ). . . . .	102
4.16	Focalisation par filtrage adapté sur l'image des kurtosis d'une image contenant deux régions déterministes, en ne tenant pas compte de l'incertitude ( $25 \times 25$ ), et en tenant compte de l'incertitude ( $23 \times 23$ , écart-type = 3). . . . .	103
4.17	Modèle théorique du kurtosis utilisé pour le filtre adapté (fenêtre de taille moyenne $23 \times 23$ , écart-type = 3). . . . .	103
4.18	Reconstruction de la région déterministe, à partir de l'image des kurtosis, par dilatation. . . . .	105
4.19	Élément structurant de la dilatation utilisée pour la reconstruction de la région déterministe ( $11 \times 11$ , écart-type = 1). . . . .	105
4.20	Valeurs des SOS sur un fond bruité (Weibull) en fonction du paramètre $\delta$ . . . . .	107
4.21	Valeurs des skewness et kurtosis en fonction de la proportion de pixels déterministes $p$ et du RSB ( $\delta = 1, 65$ ). . . . .	109
4.22	Valeurs des skewness et kurtosis en fonction du RSB pour des valeurs de $p$ faibles (trait continu) ou élevées (traits pointillés) ( $\delta = 1, 65$ ). . . . .	109
4.23	Valeurs des skewness (traits pointillés) et kurtosis (trait continu) en fonction du paramètre $p$ pour des RSB faibles et élevés ( $\delta = 1, 65$ ). . . . .	110
4.24	Image C et partie gauche de l'image. . . . .	113
4.25	Images des kurtosis sur l'image C (fenêtre $11 \times 11$ ). . . . .	113
4.26	Focalisation des kurtosis sur l'image C (taille estimée des objets : moyenne = $5 \times 5$ , écart-type = 1). . . . .	114
4.27	Reconstruction des objets à partir du kurtosis sur l'image C (paragraphe 4.3.5.3). . . . .	114
4.28	Image des skewness sur l'image C (fenêtre $11 \times 11$ ). . . . .	115
4.29	Images des skewness de l'image C après focalisation et reconstruction (taille estimée des objets : moyenne = $5 \times 5$ , écart-type = 1). . . . .	115
4.30	Performances des SOS sur l'image C comparées avec un simple seuillage. . . . .	115
4.31	Image D. . . . .	116
4.32	Images des kurtosis de l'image D, focalisation et reconstruction (fenêtre $55 \times 55$ , taille estimée des objets : moyenne = $11 \times 11$ , écart-type = 3). . . . .	116
4.33	Images des skewness de l'image D, focalisation et reconstruction (fenêtre $55 \times 55$ , taille estimée des objets : moyenne = $11 \times 11$ , écart-type = 3). . . . .	117
4.34	Performances des SOS sur l'image D comparées avec un simple seuillage. . . . .	117
4.35	Image E. . . . .	118
4.36	Images des kurtosis de l'image E, focalisation et reconstruction (fenêtre $55 \times 55$ , taille estimée des objets : moyenne = $11 \times 11$ , écart-type = 3). . . . .	118
4.37	Images des skewness de l'image E, focalisation et reconstruction (fenêtre $55 \times 55$ , taille estimée des objets : moyenne = $11 \times 11$ , écart-type = 3). . . . .	118
4.38	Performances des SOS sur l'image E comparées avec un simple seuillage. . . . .	119
4.39	Image B. . . . .	119

4.40	Images des kurtosis de l'image B, focalisation et reconstruction (fenêtre $21 \times 21$ , taille estimée des objets : moyenne = $5 \times 5$ , écart-type = 1). . . . .	119
4.41	Images des skewness de l'image B, focalisation et reconstruction (fenêtre $21 \times 21$ , taille estimée des objets : moyenne = $5 \times 5$ , écart-type = 1). . . . .	120
4.42	Performances des SOS sur l'image B comparées avec un simple seuillage. . . . .	120
5.1	Performances des différents paramètres extraits des images SAS en terme de détection. . . . .	131
5.2	Schéma du processus de fusion. . . . .	132
5.3	Définition des fonctions de masse. . . . .	133
5.4	Définition des fonctions de masse pour les premiers ordres statistiques : exemple de l'image D (on a $s_2 - s_1 = s_4 - s_3 = \sqrt{\mathcal{V}(\hat{\sigma}_F)}$ , en rouge : seuils déterminés par la segmentation automatique). . . . .	134
5.5	Définition des fonctions de masse pour les statistiques d'ordres supérieurs. . . . .	135
5.6	Exemples d'histogramme et d'histogramme cumulé normalisés de l'image des kurtosis (focalisée et reconstruite) de l'image C. . . . .	135
5.7	Images des masses obtenues pour les différentes classes pour le paramètre moyenne / écart-type (segmentation) sur l'image C. . . . .	141
5.8	Images des masses obtenues pour les différentes classes pour le paramètre skewness sur l'image C. . . . .	141
5.9	Images des masses obtenues pour les différentes classes pour le paramètre kurtosis sur l'image C. . . . .	141
5.10	Images des masses obtenues après fusion des trois paramètres sur l'image C. . . . .	142
5.11	Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image C. . . . .	142
5.12	Images des masses obtenues pour les différentes classes pour la fusion des paramètre moyenne / écart-type (segmentation) et skewness sur l'image C. . . . .	143
5.13	Images des masses obtenues pour les différentes classes pour la fusion des paramètre moyenne / écart-type (segmentation) et kurtosis sur l'image C. . . . .	143
5.14	Courbes COR comparées des trois paramètres fusionnée et des résultats de la fusion (plausibilité et croyance) sur l'image C. . . . .	145
5.15	Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image D. . . . .	148
5.16	Courbes COR comparées des trois paramètres fusionnés et des résultats de la fusion (plausibilité et croyance) sur l'image D. . . . .	148
5.17	Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image E. . . . .	149
5.18	Courbes COR comparées des trois paramètres fusionnés et des résultats de la fusion (plausibilité et croyance) sur l'image E. . . . .	149
5.19	Images des croyances et des plausibilités obtenues après fusion des trois paramètres sur l'image B. . . . .	150
5.20	Courbes COR comparées des trois paramètres fusionnés et des résultats de la fusion (plausibilité et croyance) sur l'image B. . . . .	150

---

5.21	Présentations des résultats de la fusion sur l'image C. . . . .	152
5.22	Présentations des résultats de la fusion sur l'image D. . . . .	153
5.23	Présentations des résultats de la fusion sur l'image B. . . . .	154
5.24	Présentations des résultats de la fusion sur l'image B. . . . .	155
5.25	Exemple d'utilisation de données morphologiques dans un processus de fusion sur l'image D. . . . .	157
A.1	Image sonar B et image des croyance associée. . . . .	162
A.2	Filtre moyennneur $5 \times 5$ . . . . .	163
A.3	Filtre moyennneur adaptatif $5 \times 5$ , $\tau = 1000$ . . . . .	164
A.4	Filtre à diffusion anisotrope $3 \times 3$ , $\tau' = 1000$ , 20 itérations. . . . .	165
A.5	Filtre médian $5 \times 5$ . . . . .	166
A.6	Filtre homomorphique moyennneur $5 \times 5$ . . . . .	167
A.7	Filtre de Lee $5 \times 5$ . . . . .	168
A.8	Filtre à diffusion anisotrope adaptatif $3 \times 3$ , $\tau' = 1000$ , itérations de 1 à 20. . . . .	169
A.9	Comparaison des échos sur les images B zoomées originale et filtrés par diffusion anisotrope. . . . .	170
A.10	Comparaison des échos sur les images C zoomées originale et filtrés par diffusion anisotrope $7 \times 7$ (les autres paramètres sont identiques à ceux de l'image B). . . . .	170



# Liste des tableaux

2.1	Comparaison des performances des différents modèles statistiques sur l'image A. . . . .	48
2.2	Comparaison des performances des différents modèles statistiques sur l'image C. . . . .	49
2.3	Comparaison des performances des différents modèles statistiques sur l'image D. . . . .	50
4.1	Comparaison des performances de détection des SOS (variance du fond et contraste), pour un RSB de -60dB, en fonction de la taille de la fenêtre de calcul. . . . .	93
4.2	Comparaison des contrastes des SOS, pour un RSB de 50dB ( $\approx 316, 2$ ), en fonction de la taille de la fenêtre de calcul. . . . .	97
4.3	Comparaison des contrastes des SOS, pour un RSB de 0dB ( $= 1$ ), en fonction de la taille de la fenêtre de calcul. . . . .	100
4.4	Comparaison des contrastes des SOS, pour un RSB de 20dB ( $= 10$ ), en fonction de la taille de la fenêtre de calcul. . . . .	100
5.1	Table de décision pour la fusion de deux paramètres. . . . .	136
5.2	Performances de la fusion des différents paramètres sur l'image C, . . . . .	146
5.3	Performances de la fusion des différents paramètres sur l'image D, . . . . .	146
A.1	Performances des filtres simples sur l'image sonar B. . . . .	166
A.2	Performances des filtres adaptés au speckle sur l'image sonar B. . . . .	168
A.3	Performances des filtres à diffusion anisotrope. . . . .	169





---

## Résumé

La détection et la classification d'objets enfouis est un problème particulièrement délicat : les techniques de sonar à antenne synthétique utilisées pour imager le fond sous-marin fournissent des mesures possédant souvent un très faible rapport signal à bruit, d'où un nombre important de fausses alarmes. L'objectif de la thèse est de concevoir et développer des algorithmes permettant de réduire le nombre de fausses alarmes, tout en conservant une bonne détection, et éventuellement de classifier les objets détectés, grâce à des outils de traitement d'images et de fusion de données.

Pour cela, on utilise les propriétés statistiques aux ordres 1, 2, 3 et 4 de ces images sonar qui vont nous permettre de développer des algorithmes de détection performants. Afin d'améliorer le résultat, les données ainsi extraites sont fusionnées dans un processus basé sur la théorie de l'évidence. Ceci permet de classifier chaque pixel de l'image en "objet" ou "non objet" selon qu'il est supposé appartenir à un objet recherché (mine sous-marine par exemple) ou pas. Le résultat pourra alors être utilisé par un expert afin de l'aider dans sa prise de décision.

---

**Mots clés :** Imagerie sonar, détection, modélisation statistique, segmentation, statistiques d'ordres supérieurs, fusion de données, Sonar à Antenne Synthétique (SAS).

---

## Abstract

Detection and classification of buried objects is a particularly difficult problem : synthetic aperture sonar techniques used for seabed imagery provide data with very low signal to noise ratio, and then a large number of false alarms. The goal of this thesis is to make and develop algorithms allowing to reduce the number of false alarms, by keeping a good detection, and eventually to classify the detected objects, thanks to image processing and data fusion tools.

For that, 1st, 2nd, 3rd, and 4th order statistical properties of these images are used in order to develop efficient detection algorithms. To improve the results, the data extracted by these means are combined by a fusion process using the theory of evidence. This allows to classify each pixel of the image into "object" or "not object" depending on whether it is supposed to belong to a sought object (underwater mine for example) or not. The result can then be used by an expert in order to help him in his decision.

---

**Key words :** Sonar imaging, detection, statistical modeling, segmentation, higher order statistics, data fusion, Synthetic Aperture Sonar (SAS).

---

Laboratoire des Images et des Signaux (CNRS UMR 5083)  
LIS / ENSIEG, Domaine Universitaire, BP 46,  
38402 St-Martin-d'Hères Cedex, France