



HAL
open science

Détection et analyse des évènements rares par approche sémantique dans une image naturelle

Imen Mandhouj

► **To cite this version:**

Imen Mandhouj. Détection et analyse des évènements rares par approche sémantique dans une image naturelle. Traitement des images [eess.IV]. Télécom Bretagne; Université de Bretagne Occidentale, 2016. Français. NNT: . tel-01404941

HAL Id: tel-01404941

<https://hal.science/tel-01404941>

Submitted on 29 Nov 2016

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 BRETAGNE LOIRE

THÈSE / Télécom Bretagne

sous le sceau de l'Université Bretagne Loire

pour obtenir le grade de Docteur de Télécom Bretagne

En accréditation conjointe avec l'Ecole Doctorale Sicma
et en cotutelle avec Ecole Nationale d'Ingénieurs de Tunis

Mention : Sciences et Technologies de l'Information et de la Communication

présentée par

Imen Mandhouj

préparée dans le département Image et Traitement de l'Information
Laboratoire Labsticc – Pôle CID

Détection et analyse des événements rares par approche sémantique dans une image naturelle

Thèse soutenue le 15 janvier 2016
Devant le jury composé de :

Imed Riadh Farah
Maître de conférences - HDR, Université de la Manouba / président

Mohamed Saber Naceur
Professeur, INSAT - Tunisie / rapporteur

Jean-Paul Haton
Professeur, Université de Lorraine / rapporteur

Basel Solaiman
Professeur, Télécom Bretagne / directeur de thèse

Hamid Amiri
Professeur, Ecole Nationale d'Ingénieurs de Tunis - Tunisie / co-directeur de thèse

Frédéric Maussang
Maître de conférences, Télécom Bretagne / examinateur

Ali Khenchaf
Professeur, ENSTA Bretagne / invité

Sous le sceau de l'Université Bretagne Loire

Télécom Bretagne

En accréditation conjointe avec l'Ecole Doctorale Sicma

Co-tutelle avec l'École Nationale d'Ingénieurs de Tunis (ENIT)

Détection et analyse des événements rares par approche sémantique dans une image naturelle

Thèse de Doctorat

Mention: Sciences et Technologies de l'Information et de la Communication

présentée par : **Imen MANDHOJ**

Départements :

Image et Traitement de l'information (ITI), Télécom Bretagne
Traitement du signal de l'image et Reconnaissance des formes, ENIT

Laboratoires :

Lab-STICC/CID, Télécom Bretagne
Signal, Image et Technologies de l'Information, ENIT

Directeurs :

Basel Solaiman
Hamid Amiri

Soutenue le 15/01/2016

Jury

M. Mohamed Saber Naceur,	Professeur, INSAT Tunis	Rapporteur
M. Jean-Paul Haton,	Professeur, Université Henri Poincaré Nancy 1	Rapporteur
M. Basel Solaiman,	Professeur, Télécom Bretagne	Directeur de Thèse
M. Hamid Amiri,	Professeur, ENIT Tunis	Directeur de Thèse
M. Frédéric Maussang,	Maitre de conférences, Télécom Bretagne	Encadrant de la thèse
M. Imed Riadh Farah,	Maître de conférences à l'Université de la Manouba	Examineur
M. Ali Khenchaf,	Professeur, ENSTA Bretagne	Invité

A **mes parents**,
pour leur soutien incessant.

A **mon mari**,
pour sa patience et son soutien.

A **Youssef**
parce qu'il est notre rayon de soleil.

Remerciements

Je tiens à exprimer toute ma reconnaissance à mon directeur de thèse Monsieur Basel SOMAIMAN, pour m'avoir accueilli au sein du département Image et Traitement de l'Information (ITI). Je le remercie pour m'avoir accordé sa confiance et de m'avoir me redonner le goût de faire une thèse. C'est à grâce à lui que je dois ma continuité dans le monde de recherche. Je le remercie également pour son accueil durant tous mes stages à l'ITI, ses précieux conseils et ses qualités humaines que m'ont beaucoup apporté.

J'exprime toute ma reconnaissance à Frédéric MAUASSANG qui a assuré l'encadrement de ma thèse avec beaucoup de disponibilité. Je le remercie pour ses nombreux conseils, son soutien constant tout au long de ce travail de thèse et ses efforts pour corriger mes rédactions. Des nombreuses parties de mon travail de thèse n'auraient pu voir le jour sans ses suggestions et ses encouragements.

J'adresse également mes remerciements à Monsieur Hamid AMIRI, mon directeur de thèse à l'Ecole Nationale d'Ingénieurs de Tunis (ENIT), pour m'avoir accueilli au sein de l'équipe de traitement du signal, de l'image et reconnaissance des formes.

Je tiens à exprimer ma profonde reconnaissance à Monsieur Jean Paul HATON, Professeur à l'Université Henri Poincaré Nancy 1, et Monsieur Mohamed Sabeur Naceur, Professeur à l'INSAT, d'avoir bien voulu accepter la charge de rapporteur.

Je remercie également Monsieur Ali KHENCHAF, Professeur à l'ENSTA Bretagne, et Monsieur Imed Riadh FARAH, Maître de conférences à l'Université de la Manouba, qui m'ont fait plaisir de participer à ce jury.

Je veux remercier également l'équipe du labo ITI, pour la chaleur de l'accueil et pour la spontanéité des échanges constructifs qui s'y déroulent durant mes séjours à Brest. Je remercie chaleureusement mes amis, en Tunisie et à Brest, qui m'ont accompagnée tout au long de cette thèse.

Je voudrais enfin remercier tout particulièrement mes proches qui m'ont soutenue dans mon projet professionnel. Toute ma gratitude à ma famille et ma belle famille qui m'ont toujours offert l'affection et la compréhension. Merci à mon cher papa d'avoir toujours été là et de m'avoir tant aidé. Merci à mes chères belles sœurs qui m'ont soutenue et encouragée tout au long de ces années.

Toutes ces remerciements ne seraient pas complets sans mentionner mon mari Momo et Youssef notre petit garçon. Merci de m'avoir soutenue et supportée, merci d'être là.

Résumé

La détection des objets rares joue un rôle important dans différentes disciplines. Dans la littérature, le terme « objet rare » ou « événement rare » est différemment apprécié en fonction des événements rencontrés, de l'état initial, de l'intention de l'utilisateur et du domaine d'application. Les recherches s'intéressant au développement des algorithmes permettant la détection générale des objets rares, et pouvant être partagés par différents domaines d'applications, sont extrêmement limitées.

Cette thèse propose une nouvelle approche sémantique pour la détection automatique des objets rares dans une image naturelle. Contrairement aux travaux s'intéressant à une particularité définie d'un objet rare, l'approche proposée permet de différencier deux catégories principales d'objets : « objet marquant » et « objet rare ». Nous désignons par le terme « objet rare » tout objet peu fréquent qui s'écarte significativement de la majorité des objets fréquemment rencontrés dans l'image. Les objets marquants sont aussi des objets d'une fréquence faible. Cependant, ces objets ne nécessitent pas autant d'intérêt que les objets rares. L'approche de détection proposée est réalisée en deux étapes décisives. Dans une première étape, nous développons une nouvelle approche de segmentation basée sur une mesure qualitative de la quantité d'information permettant de localiser les objets d'intérêt dans l'image. Dans l'étape suivante, nous développons une méthode sémantique de fouille des données fondée sur un raisonnement hypothétique. Nous visons à exploiter l'information en continu dans ces données et d'en extraire une sémantique fiable pour la caractérisation commune d'objets rares. La détection finale de l'objet rare est basée sur les méthodes d'apprentissage et la classification non supervisée. Un système de détection de la saillance visuelle est utilisé pour décider de la différenciation entre l'objet marquant et l'objet rare.

Dans ce travail, nous avons défini une nouvelle approche de pré-traitement des images et un système de raisonnement à base de cas pour améliorer les performances du travail réalisé. L'approche que nous avons proposée ne nécessite aucune connaissance préalable sur la nature des objets ni une intervention extérieure. Les résultats d'évaluation de notre approche sur des images réelles et synthétisées ont montré l'efficacité du modèle proposé.

Mots clés: Objet rare, détection générale, fossé sémantique, segmentation automatique, raisonnement hypothétique, méthodes d'apprentissage, saillance visuelle, prétraitements, raisonnement à base de cas.

Abstract

The detection of rare objects plays an important role in different disciplines. In literature, the term "rare item" or "rare event" is differently appreciated depending overall on the events encountered, the initial state, user intention and the working environment. Searches interested to the development of rare object general detection algorithms, shared by different fields of application, are extremely limited.

This thesis proposes a new semantic approach for automatic detection of rare objects in a natural image. Contrary to the work concerned with a feature set of a rare item, the proposed approach can differentiate two main categories of objects "aberrant object" and "rare object". By rare object, we mean extremely different objects from usual components of a given image whose characteristics make them highly valuable. A rare object is for us an unusual event with a low probability of occurrence. Aberrant objects are also objects of a lower frequency. However, these objects do not require much interest as the rare items. The proposed detection approach is performed in two critical steps. In the first step, we developed a new segmentation approach based on a qualitative measure of the amount of information to locate objects of interest in the image. In the next step, we developed a semantic data mining method based on a hypothetical reasoning. We aim to exploit continuously the information in these data and to extract reliable common semantics to characterize rare items. The final detection of the rare objects is based on learning methods and unsupervised classification. A salience detection approach is used to decide the differentiation between the rare and the aberrant object.

In this work, a new approach to pre-process image and a case-based reasoning system are used to improve the performance of the process. Our approach does not require any prior knowledge about the nature of objects nor external intervention. The process is tested on the special case of real and synthesized images. Results of evaluation show the efficiency of the proposed method.

Keywords: Rare object, detection, semantic gap, automatic segmentation, hypothetical reasoning, learning methods, saliency detection, pre-processing, case based reasoning.

Liste des figures

1.1	Diagramme du système de détection des objets rares dans une image donnée.	11
1.2	Exemples d'applications de détection des événements rares dans différents types d'images naturelles.	14
1.3	Processus d'extraction de connaissances à partir d'une base de données.	19
1.4	Fossé sémantique : écart de description du contenu de l'image en vision par ordinateur et chez l'être humain.	22
1.5	Description du concept de l'ontologie : relation intermédiaire entre l'image et la sémantique.	23
2.1	Application des différents types de bruit sur l'image de Lena.	28
2.2	Illustration du principe du filtrage spatial en fonction du voisinage.	32
2.3	prétraitement d'une image radar bruitée (bruit gaussien) par filtre moyen	32
2.4	prétraitement de l'image de Barbara bruitée (bruit "poivre et sel") par filtre médian	33
2.5	Types de filtres usuels	34
2.6	Filtre homomorphique de Lena	35
2.7	Détection d'un objet par un système sonar.	35
2.8	Exemple d'une image SAS présentant des objets enfouis et posés sur le sédiment marin.	37
2.9	Illustration du filtre homomorphique. (a) image d'origine, (b) image rehaussée par le filtre homomorphique avec $l = 0.1$, $h = 1.5$ et $\delta_w = 0.2$ et (c) image rehaussée en fixant les valeurs des paramètres : $l = 0.9$, $h = 1.1$ et $\delta_w = 0.2$	39
2.10	Image2 de test contenant des objets enfouis (b) et posés ((a) et (c)) sur le sédiment marin (GESMA).	41
2.11	Comparaison entre l'image de test et l'image filtrée pour différentes valeurs de l et h . La figure (a) présente l'image initiale, les figures (b), (c) et (d) présentent le résultat de l'application de filtre homomorphique respectivement dans les cas 1, 2 et 3.	43
2.12	Résultats d'application successive du filtre homomorphique sur l'image SAS de test en considérant le cas1.	43
2.13	Modélisation de l'image sonar par la loi gaussienne et illustration des résultats pour différentes valeurs des paramètres h et l	45
2.14	Modélisation par la loi gaussienne pour l'image initiale et filtrée (cas1).	45
2.15	Modélisation par la loi gaussienne et la loi de Rayleigh de l'image filtrée ($l = 0,1$, $h = 1,5$ et $\delta_w = 0,2$) et comparaison avec la loi empirique de l'image	46
2.16	Allure de la fonction de répartition empirique de l'image initiale.	49
2.17	Allure de la fonction de répartition empirique de l'image sonar après application de la méthode de filtrage.	49

2.18	Illustration de Q-Q plot de deux échantillons avant et après application de l'approche de filtrage (l'échantillon est coloré en bleu et la normale est présentée par la droite rouge).	52
3.1	Comparaison de résultats de seuillage de l'image de Lena.	58
3.2	Comparaison de résultats de seuillage d'une image astronomique.	59
3.3	Seuillage global d'une image mammographique (seuil=170). L'image est de taille (1024 · 1024), la profondeur de l'image est 8 et le niveau de gris maximal est 248.	61
3.4	Allure unimodale de l'histogramme de l'image radar.	62
3.5	Seuillage unimodal par la méthode du triangle (Rosin).	63
3.6	Image de test filtrée adoptée pour tester des méthodes de seuillage unimodal.	64
3.7	Application de la méthode d'Otsu pour le seuillage de l'image SAS de test.	65
3.8	Application de la méthode de p-tile (p=20%) pour le seuillage de l'image SAS de test.	65
3.9	Application de la méthode de Voorhees et Poggio pour le seuillage de l'image SAS de test.	66
3.10	Application de la méthode de triangle pour le seuillage de l'image SAS de test.	66
3.11	Distribution unimodale.	70
3.12	Position approximative du seuil d'activation dans la courbe de perte en entropie.	70
3.13	Illustration de la courbe de la perte en entropie en fonction de la valeur de seuil.	71
3.14	Allure de la courbe d'entropie très proche de celle d'une sigmoïde.	72
3.15	Estimation de la courbe d'entropie par différentes fonctions sigmoïdes pour le cas de l'image réelle de test.	73
3.16	Application de la méthode de l'EQM de la deuxième étape : modélisation finale de la courbe de l'entropie.	74
3.17	Variations des dérivées 1 ^{re} et 2 ^e de la fonction sigmoïde estimée dans le cas de l'image de test.	74
3.18	Résultat du seuillage de l'image SAS par la valeur calculée de seuil (s=9140)	75
3.19	Vérité terrain de l'image sonar de test	76
3.20	Seuillage local de l'image sonar en utilisant une fenêtre de taille 40 × 40.	77
3.21	Variation de taux d'occupation des objets en fonction du paramètre λ (cas des images synthétisées par la loi normale).	81
3.22	Droite de régression moyenne estimant la variation du paramètre de la sigmoïde en fonction du pourcentage d'occupation des images par des objets d'intérêt.	82

3.23	Exemples d'images de synthèse contenant différents pourcentages d'occupation par les objets et classées selon la valeur de λ . L'image (a) montre une forte probabilité d'occupation par des objets ($\lambda = 2,203$), l'image (b) montre une probabilité moyenne de présence d'objets ($\lambda = 1,698$) et l'image (c) présente une probabilité proche de zéro de présence d'objet. ($\lambda = 0,674$).	83
3.24	Courbe COR : taux de détection en fonction du taux de fausse alarme pour différentes valeurs de α	84
4.1	Diagramme de description des objets.	97
4.2	Les caractéristiques sémantiques et géométriques calculées pour un échantillon d'objets de classes différentes.	101
4.3	Schéma simplifié de la combinaison des sorties de classifieurs.	105
4.4	Exemple d'une image de test issue de la base de données synthétisées.	107
4.5	Évaluation des performances des trois classifieurs et du résultat de combinaison en taux de reconnaissance des objets marquants ($\max=1$).	108
4.6	Variation du taux des fausses absences des objets marquants pour les trois classifieurs et résultat de combinaison ($\max=1$).	109
4.7	Classification de l'image de test en utilisant différents classifieurs et résultats de la combinaison.	109
4.8	Exemple de résultats de fausses classifications des objets habituels.	109
4.9	Diagramme illustrant la détection des objets rares à partir de la base des objets marquants.	110
4.10	Système d'attention visuelle <i>bottom-up</i>	112
4.11	Diagramme illustrant la procédure d'apprentissage pour la détection de la saillance.	115
4.12	Exemple de spectre logarithmique de l'image sonar	116
4.13	Détection de la saillance dans la base de données synthétisées.	116
5.1	Prétraitement de l'image mammographique	124
5.2	Application de la méthode de filtrage sur une image mammographique réelle (MIAS).	125
5.3	Localisation de la zone d'intérêt dans une image de la base MIAS.	126
5.4	Illustration de la nature unimodale d'un exemple de zone d'intérêt dans la base MIAS	127
5.5	Application de notre approche de segmentation sur un échantillon d'images mammographiques présentant des micro-calcifications (de MIAS). La première colonne présente les images avec la zone d'intérêt entourée en rouge, la deuxième présente les courbes résultats de l'application de la méthode de segmentation et la troisième colonne présente les résultats de la segmentation de la zone d'intérêt par les seuils résultants.	129
5.6	Illustration des différents cas possibles dans la matrice de confusion	130
5.7	Image originale avec des objets astronomiques synthétisés.	133
5.8	Courbe COR pour différentes approches de <i>clustering</i>	135
5.9	Cycle du raisonnement à base de cas.	137

5.10	Structure du système proposé pour la détection des objets rares dans une image.	143
A.1	Estimation de la droite de variation de paramètre λ en fonction de pourcentage d'occupation des objets dans l'image.	154
A.2	Droite de régression moyenne estimant la variation du paramètre de la sigmoïde en fonction du pourcentage d'occupation des images par des objets d'intérêt.	155

Liste des tableaux

2.1	Évaluation de la méthode de filtrage pour un échantillon de deux images sonars	41
2.2	Évaluation de la méthode de filtrage pour différentes valeurs de l et h	42
2.3	Calcul des paramètres estimés des trois modèles statistiques pour l'image initiale et l'image filtrée	47
2.4	Comparaison des distributions de chacun des modèles statistiques pour un échantillon de deux images sonars ($l = 0, 1$ $h = 1, 5$ et $\delta_w = 0, 2$)	48
2.5	Résultats du calcul de p-valeur pour le test de Cramer appliqué sur l'image SAS	48
2.6	Comparaison de la valeur de l'indicateur usuel de normalité I pour le cas de l'image SAS avant et après application de la méthode de filtrage.	50
3.1	Résultats de simulation d'un échantillon de 100 images ne contenant aucun objet.	78
3.2	Résultats de simulation d'un échantillon de 100 images contenant un seul objet.	78
3.3	Résultats de simulation d'un échantillon de 100 images contenant deux objets.	79
3.4	Résultats de simulation d'un échantillon de 100 images contenant trois objets.	79
3.5	Résultats de simulation d'un échantillon de 100 images contenant six objets.	80
3.6	Résultats de simulation d'un échantillon de 100 images contenant vingt objets.	80
3.7	Matrice de confusion pour la présence/absence des objets d'intérêt.	83
3.8	Matrice de confusion pour le cas de $\alpha = 0,05$ appliquée sur la base de données synthétisée.	83
4.1	Matrice de confusion de classification marquant-ordinaire.	107
5.1	Classification des cinq types de microcalcifications de Le Gal.	123
5.2	Calcul des paramètres de seuillage pour un échantillon d'images mammographiques.	130
5.3	Mesures de performance pour la reconnaissance des objets marquants.	134
5.4	Représentation numérique des objets rares détectée dans une image quelconque.	144
5.5	Description de la base de cas	144
A.1	Calcul des statistiques de test de KS pour l'image SAS avant et après le filtrage H.	150
A.2	Test de normalité réalisé avec la méthode de Khi-deux et appliqué sur l'image SAS avant et après le filtrage homomorphique.	151

Table des matières

Liste des figures	vi
Liste des tableaux	xi
Introduction	1
1 Contexte et état de l'art	7
1.1 Introduction	9
1.2 Les enjeux et les besoins	9
1.2.1 Qu'est-ce qu'un objet rare?	9
1.2.2 Défis et motivations	10
1.2.3 Problématique	11
1.3 Les différents types d'applications	13
1.4 Modélisation d'un objet rare	15
1.5 Détection générale d'un objet	17
1.6 Extraction des connaissances et sémantique des images	18
1.6.1 Extraction des connaissances à partir d'une base de données	18
1.6.2 Étapes d'extraction de connaissances à partir d'une base de données	19
1.6.3 La sémantique dans l'image	21
1.6.4 Fossé sémantique et travaux connexes	21
1.7 Conclusions	23
2 Prétraitement des images naturelles : Application au cas des images sonars	25
2.1 Introduction	27
2.2 État de l'art : le bruit dans une image naturelle	27
2.2.1 Débruitage des images : sources et types de bruit	27
2.2.2 Autres éléments à corriger dans une image bruitée	30
2.3 Débruitage des images par filtrage	31
2.3.1 Filtrage spatial	31
2.3.2 Filtrage fréquentiel ou spectral	33
2.3.3 Le filtre homomorphique	34
2.4 Exemple de prétraitement d'une image naturelle : cas d'une image sonar	35
2.4.1 Prétraitement d'une image sonar	36
2.4.2 Rehaussement homomorphique des images	37
2.5 Définition de critères d'évaluation de la méthode de filtrage	39
2.6 Modélisation statistique et estimation des paramètres	44
2.6.1 Modélisation par la loi normale	44
2.6.2 Modélisation par la loi de Rayleigh	46
2.6.3 Modélisation par la loi de Weibull	46
2.7 Évaluation des performances des modèles statistiques	47
2.8 Tests d'hypothèse et analyse des résultats obtenus	48

2.9	Tests de normalité : méthodes empiriques et graphiques	50
2.9.1	Indicateur de normalité	50
2.9.2	Le Q-Q plot et la droite de Henry	50
2.10	Conclusions	52
3	Segmentation des images : pré-détection des objets rares	55
3.1	Introduction	57
3.2	Segmentation des images	57
3.2.1	Approches région	57
3.2.2	Approches contour	58
3.2.3	Méthodes sur histogramme	59
3.3	Techniques de binarisation et choix du seuil	60
3.3.1	Seuillage global	60
3.3.2	Seuillage local	60
3.3.3	Seuillage hybride	60
3.4	Seuillage d'une image unimodale	61
3.4.1	Différentes approches existantes	62
3.4.2	Seuillage global automatique	64
3.5	Étude théorique de l'approche de segmentation	67
3.5.1	Seuillage entropique	67
3.5.2	Entropie et hypothèses de calcul	68
3.5.3	Variation de l'entropie en fonction du seuil de segmentation	70
3.5.4	Fonction Sigmoidale	71
3.6	Seuillage entropique et pré-détection des objets d'intérêt	71
3.6.1	Estimation de la courbe d'entropie	71
3.6.2	Étude des variations de la fonction d'estimation et seuillage de l'image sonar.	73
3.6.3	Algorithme de pré détection des objets d'intérêts	76
3.7	Variations de λ en fonction du pourcentage d'occupation en objets de l'image	77
3.8	Tests et évaluation des performances	82
3.9	Conclusions	84
4	Caractérisation et détection des objets rares	87
4.1	Introduction	89
4.2	Caractérisation et classification des objets marquants	89
4.2.1	Méthodes existantes	89
4.2.2	Les différents mécanismes d'apprentissage	94
4.3	Notre approche de détection des objets marquants	96
4.3.1	Caractérisation des objets	96
4.3.2	Classification non supervisée	101
4.3.3	Combinaison des classifieurs	104
4.3.4	Tests et évaluation des résultats	106
4.4	Détection des objets rares : application de la saillance visuelle	110
4.4.1	Rareté et saillance visuelle	110
4.4.2	Carte de saillance	111

4.4.3	Techniques de détection de la saillance dans le domaine transformé	113
4.5	Localisation finale des objets rares	114
4.5.1	Algorithme implémenté	114
4.5.2	Tests et résultats	115
4.6	Conclusions	117
5	Système de détection d'un événement rare	119
5.1	Introduction	121
5.2	Détection des objets rares dans une image médicale	121
5.2.1	Détection des microcalcifications	122
5.2.2	Description de la base de données	123
5.2.3	Prétraitements de l'image mammographique	124
5.2.4	Segmentation des zones d'intérêt: application de notre approche	126
5.3	Détection des objets rares dans une image astronomique	131
5.3.1	Différentes classes d'objets	132
5.3.2	Détection des objets marquants	132
5.3.3	Tests et évaluations	133
5.4	Système de raisonnement à base de cas	135
5.4.1	Qu'est-ce qu'un raisonnement à base de cas ?	135
5.4.2	Intégration de raisonnement à base de cas dans notre système	136
5.4.3	Processus	137
5.4.4	Différents modèles	139
5.4.5	Modèle textuel	140
5.5	RBC pour la détection des objets rares	140
5.6	Conclusions	144
A	Modélisation statistique de l'image sonar	149
A.1	Introduction	149
A.2	Tests d'hypothèses et analyse des résultats obtenus	149
A.2.1	Test de Shapiro-Wilk	149
A.2.2	Test de Kolmogorov Smirnov	150
A.2.3	Test de Lilliefors	151
A.2.4	Test de khi-deux	151
A.2.5	Test de Cramer	151
A.3	Modèle probabiliste de présence des objets d'intérêt	152
A.3.1	Régression Linéaire	152
A.4	Conclusions	153
B	La fusion de données	157
B.1	Introduction	157
B.2	Les différentes approches de fusion	157
B.3	La fusion globale	158
B.4	Imperfections de l'information	158
B.5	Méthodes de la fusion	159
B.5.1	Méthodes du vote	159

B.5.2	L'approche bayésienne	159
B.5.3	La théorie des croyances	160
B.6	Conclusions	161
Liste de mes publications		163
Bibliographie		165

Introduction

Contexte du travail

De nos jours, la détection des objets est un défi fondamental en vision par ordinateur et dans les recherches en traitement d'images. Dans ce présent travail de thèse, nous traiterons le problème de détection des objets rares dans une image réelle telle qu'une image sonar, radar, médicale, astronomique, etc. Dans ce contexte, le terme « objet rare » ou « événement rare » désigne les objets atypiques dont la fréquence d'apparition est très faible. Contrairement aux objets classiques, ces objets peuvent être des objets anormaux ou inhabituels ou simplement des objets distincts du reste des données. Dans cette thèse, nous proposons un modèle de détection général de ces objets dont les différentes étapes du processus de connaissance sont mises en œuvre avec le minimum de référence à des connaissances statistiques.

Dans la littérature, les recherches s'intéressant aux approches de détection des objets rares partagées par différents domaines d'application sont extrêmement limitées voir inexistantes. La détection automatique et l'extraction de ces objets, dans le cas général, est en réalité un problème non trivial. En général, un algorithme de détection des objets permet de définir les objets auxquels on s'intéresse. Cependant, une des difficultés principales réside dans l'obtention d'une distinction significative entre les objets rares et les objets classiques. D'autre part, la détection des objets cibles, dans le cas général, accentue le problème en raison de l'absence de contexte de la recherche. En effet, en vision par ordinateur, tout ce qui est vu est exploité et analysé relativement à des connaissances préalables sur le contexte. La détection des objets cibles exige dans la plupart des applications de traitement des images de bien connaître les caractéristiques et la nature des informations contenues dans le signal 2D qui les représente. Les propriétés générales des objets cibles dans un contexte indéfini ne sont pas susceptibles d'exister. Cette thèse propose un ensemble de solutions en vue de surmonter les différentes difficultés de la détection d'un objet rare dans un cadre général.

Contrairement aux travaux s'intéressant à une particularité définie d'un objet rare, l'approche proposée permet de différencier deux catégories principales d'objets: « objet marquant » et « objet rare ». Par objet rare, nous désignons les objets extrêmement différents de composants habituels d'une image donnée et dont les caractéristiques les rendent très précieux. Les objets marquants sont aussi des objets d'une fréquence faible. Cependant, ces objets ne nécessitent pas autant d'intérêt que les objets rares. Considérant un ensemble de données, l'objet rare apparaît avec une extrême rareté voire pas du tout. Les objets marquants, par contre, apparaissent plus souvent mais ils ne sont pas aussi fréquents que les objets ordinaires et peuvent, dans certains cas, présenter quelques particularités. Par exemple dans le cas des images médicales, la présence d'une tumeur maligne dans un ensemble d'observations du même organe est un événement rare alors qu'une tumeur bénigne

détectée dans cet ensemble est un événement marquant. Toutefois, si on considère une base d'images des organes tumoraux, la présence d'une tumeur peut être considérée comme un événement rare si elle respecte une propriété particulière de spécificité. Une tumeur présentant une certaine forme ou structure peu distincte des autres peut être seulement considérée comme un « objet marquant. »

Face aux catégories imprévues et innombrables des modèles rencontrés, notre modèle proposé pour la détection des objets cibles se base sur l'étude de la sémantique de l'image. Ainsi, nous proposons une approche de détection indépendante des caractéristiques, des catégories ou d'autres connaissances *a priori* sur l'objet. Notre modèle est différent des modèles traditionnels reliant les objets avec des caractéristiques particulières et convertissant ainsi le problème à la détection de certaines catégories d'objets.

Nous proposons d'effectuer un raisonnement hypothétique fondé sur l'état des objets présents dans un ensemble d'images et leurs fonctionnalités disponibles. Nous visons à exploiter l'information en continu dans ces données et d'en extraire une sémantique fiable pour la caractérisation commune d'objets marquants. Un système de détection de saillance visuelle est utilisé pour décider de la différenciation distinctive entre l'objet marquant et l'objet rare. Le système de détection peut être vu comme un couplage de la vision avec la sémantique qui prend en compte le contexte de l'image. Pour améliorer les résultats de détection, nous avons développé une méthode de pré-traitement nous permettant de diminuer le contraste et uniformiser la luminance de l'image. A la fin de ce travail, nous avons appliqué une technique de raisonnement à base de cas pour améliorer les résultats de détection du système développé. Nous souhaiterons développer une approche adéquate pour les différents domaines testés où des expériences passées sont utilisées pour résoudre les nouveaux problèmes.

Notre modèle proposé ne nécessite aucune connaissance *a priori*. Cependant un ensemble d'images d'entraînement est nécessaire pour l'étape d'apprentissage. Les résultats d'évaluation de notre approche sur des images réelles de domaines variés ont montré l'efficacité du modèle proposé.

Contributions

L'objectif de notre thèse consiste à construire un modèle de détection des objets rares dans le cas général en nous basant sur la sémantique. Les contributions apportées dans le cadre de ce travail sont les suivantes:

- Nous avons constaté que la modification des paramètres du filtre homomorphique influe différemment sur la luminance et les contrastes de l'image. Nous proposons alors une méthode de prétraitement permettant de fixer les valeurs de ces paramètres de manière à améliorer les performances de filtrage. Considérant des images prises dans les mêmes conditions d'éclairage, une seule fonction de transfert sera alors utilisée. Nous montrerons (en utilisant des méthodes statistiques, empiriques et graphiques) que l'image après l'application de l'approche de prétraitement est plus adaptée à la loi normale. Ce résultat est considéré comme intéressant pour la suite de processus de détection étant

donné que beaucoup des algorithmes existants sont basés sur la gaussianité des données traitées ;

- Dans la littérature, la précision des critères d'évaluation de la méthode de filtrage n'est pas encore réalisée. Nous proposons deux nouvelles mesures de performance nous permettant d'évaluer notre méthode de prétraitement. Les paramètres d'évaluation proposés permettent de mesurer la préservation de la quantité des données d'intérêt (les objets) dans l'image et la réduction du bruit indésirable dans le fond ;
- Dans de nombreux domaines d'application, les images présentent la propriété de zones d'intérêt de taille négligeable comparée à la zone du fond. Ces images possèdent souvent une allure unimodale de leur histogramme. Nous proposons une méthode de segmentation des images unimodales basée sur la fonction de l'entropie. Contrairement aux approches de segmentation basées sur la maximisation d'entropie de Shannon, nous étudierons la fonction de perte en entropie selon le seuil de segmentation. Nous étudierons également la fonction d'estimation de la courbe qui en résulte et proposerons un algorithme permettant de déterminer le seuil global de l'image ;
- Nous proposons une nouvelle approche de détection des objets atypiques essentiellement basée sur un raisonnement hypothétique. De ce fait, nous donnons une description particulière des objets d'intérêt. Nous apprécierons ensuite l'intérêt de plusieurs méthodes de *clustering* ainsi que celui des méthodes de combinaison de classifieurs dans la fouille des données renfermant des objets atypiques. Nous montrons que le modèle de mélange gaussien (GMM) est mal adapté au problème de la découverte des objets qui s'écartent significativement de la majorité des autres.
- Nous proposons un cadre de travail basé sur le raisonnement à base de cas pour améliorer les performances de détection des objets rares.

Plan du manuscrit

Ce mémoire de thèse comporte cinq chapitres.

Nous allons tout d'abord présenter le contexte et l'état de l'art général de notre travail. Ensuite, nous présenterons le système de détection proposé et détaillerons les différentes méthodes développées. Enfin, nous appliquerons notre système sur des images réelles et nous proposerons un système de raisonnement à base de cas pour améliorer les performances de l'algorithme proposé.

Chapitre 1

Le premier chapitre décrit en détails le contexte de la thèse. En effet, pour bien comprendre le contenu de ce travail nous commençons par définir le terme "objet rare". Le chapitre présente un aperçu général de l'utilisation du terme "objet rare" dans différents domaines de traitement d'images (TI). Nous exposerons ensuite notre propre définition que nous adopterons tout au long de notre travail. Nous exposerons

également les différentes problématiques du sujet et nous énumérons nos objectifs. Tout au long de ce travail, nous détaillerons notre système de détection des objets rares dans une image donnée. Nous présenterons alors l'architecture générale de l'algorithme de détection. Les étapes de la procédure de détection seront détaillées progressivement au fur et à mesure qu'on avance dans cette thèse. Toutefois, les notions de base de notre approche de détection (telles que la sémantique et la détection générale d'un objet) seront détaillées dans ce premier chapitre.

Chapitre 2

Ce chapitre détaille nos contributions dans l'approche de prétraitement. Dans la première partie de ce chapitre, nous présenterons la notion de prétraitement des images naturelles. Nous énumérerons les différentes causes et types de prétraitement. Nous détaillerons également le filtrage et les différents types d'approches utilisés en littérature. Ensuite, nous introduirons notre approche de prétraitement basée sur le filtre homomorphique. L'algorithme de filtrage et la démarche suivie pour améliorer le contraste et la luminance seront expliqués dans la deuxième partie de ce chapitre. Dans ce chapitre, nous effectuerons aussi une étude de performances de l'approche proposée. Nous expliquerons donc les paramètres d'évaluation que nous aurons définis.

Ce chapitre présente une étude particulière du cas des images sonar. Les différents tests seront effectués sur un échantillon d'images SAS réelles et un échantillon d'images contenant des objets sonar synthétisés.

Chapitre 3

Le but de ce chapitre est d'extraire les objets d'intérêt dans une image unimodale. Le chapitre débutera par un état de l'art sur les images dont l'histogramme présente une allure unimodale. Ensuite, il présente l'approche de segmentation que nous avons développée. L'approche proposée permettra de déterminer la valeur optimale du seuil de segmentation en se basant sur les propriétés de l'entropie. Nous détaillerons donc les différentes étapes de l'algorithme de seuillage. Ensuite, nous réaliserons une étude comparative avec des méthodes de segmentation très utilisées pour le seuillage unimodal des images. Ce chapitre présente aussi quelques résultats de l'application de l'approche proposée dans le cadre du domaine sonar étudié dans le chapitre précédent. Dans la dernière partie de ce chapitre, nous évaluerons notre approche en utilisant un échantillon d'images originales contenant des objets synthétisés permettant d'adhérer au cas des images naturelles comportant des objets manufacturés.

Chapitre 4

Ce chapitre explique le processus de détection des objets rares que nous avons développé. Notre approche permet de détecter les objets rares en deux étapes complémentaires et consécutives. Dans la première étape de détection, nous exploiterons les propriétés géométriques et sémantiques des objets dans leurs images pour leur donner une description particulière. Cette caractérisation sera détaillée dans ce chapitre. Ensuite, nous appliquerons différentes méthodes de classification et nous examinerons l'apport de l'application des méthodes de combinaison des classifieurs.

En nous basant sur les résultats de la première étape, nous introduirons la phase finale de la détection. Dans cette étape nous utiliserons une méthode de détection basée sur la saillance visuelle. Nous étudierons, en particulier, l'algorithme connu de Zhang et Hou que nous adopterons dans la deuxième étape du processus de détection.

Chapitre 5

Le dernier chapitre constitue une expérimentation de l'approche proposée. Ce chapitre est divisé en deux parties. Dans la première partie, nous examinerons des images dans deux nouveaux domaines d'application : le domaine médical et le domaine astronomique. Nous étudierons également les propriétés de ces images. Les différentes méthodes de notre approche de détection sont testées sur un ensemble d'images réelles et un ensemble d'images contenant des objets synthétisés. Nous évaluons les résultats de chaque partie d'expérimentation.

Dans la deuxième partie, nous étudierons la phase finale de notre système de détection. Dans cette phase, nous proposerons d'intégrer un système de Raisonnement à Base de Cas (RBC) pour améliorer les performances de notre travail. Étant toujours intéressés par la détection des objets atypiques ayant des propriétés spécifiques, nous proposerons d'intégrer les connaissances des experts dans l'étape finale de la détection. Le système RBC détaillé dans ses différentes étapes, permet en sus des avantages du RBC, de discuter implicitement les performances de notre algorithme de détection des objets rares dans un domaine donné.

Contexte et état de l'art

Sommaire

1.1	Introduction	9
1.2	Les enjeux et les besoins	9
1.2.1	Qu'est-ce qu'un objet rare?	9
1.2.2	Défis et motivations	10
1.2.3	Problématique	11
1.3	Les différents types d'applications	13
1.4	Modélisation d'un objet rare	15
1.5	Détection générale d'un objet	17
1.6	Extraction des connaissances et sémantique des images	18
1.6.1	Extraction des connaissances à partir d'une base de données	18
1.6.2	Étapes d'extraction de connaissances à partir d'une base de données	19
1.6.3	La sémantique dans l'image	21
1.6.4	Fossé sémantique et travaux connexes	21
1.7	Conclusions	23

1.1 Introduction

L'objectif de cette thèse est le développement d'une méthode générique pour détecter les objets rares dans une image naturelle. Les conflits dans la définition du terme "objet rare", nous amènent à étudier, tout d'abord, les différentes utilisations de ce terme, dans la littérature. Ensuite, nous présentons notre propre définition ainsi que les objectifs et les différentes problématiques du sujet. Ce chapitre présente également un état de l'art de la détection générique des objets et la sémantique dans une image.

1.2 Les enjeux et les besoins

1.2.1 Qu'est-ce qu'un objet rare?

Dans la littérature, le concept d'événement rare apparaît sous plusieurs noms comme inhabituel, frappant, intéressant, irrégulier, surprenant, aberrant, saillant, Plusieurs études ont porté sur la définition de ces termes. Hawkins en 1980 [Haw80] a défini un objet aberrant comme « toute observation qui s'écarte significativement des autres observations de manière à éveiller les soupçons qu'il a été généré par un mécanisme différent ». Toma en 1998 [Tom98] considère que « lorsque la fréquence relative d'un événement est inférieure à 1% ou lorsqu'un événement ne survient que sporadiquement il est qualifié de rare ». En procédant plus simplement, Hamid *et al.* [HJB⁺05] considèrent que les objets qui ne sont pas fréquents et sont différents des cas ordinaires sont des événements rares. Différemment, Ruslan *et al.* [STT11], donnent une définition d'un événement rare basée sur la fréquence de leur rencontre. Dans leur travail, les auteurs distinguent entre les classes des objets très fréquents, moins fréquents, assez rares ou extrêmement rares. Ils utilisent la caractérisation des classes fréquentes pour définir un outil d'apprentissage pour les classes rares. Plus tard, Xiang *et al.* [XG08] définissent un événement rare comme un modèle de comportement anormal qui n'est pas représenté par des échantillons suffisants dans l'ensemble d'apprentissage, mais qui respecte la contrainte de conformité à une spécificité critique de déformation d'une configuration anormale. Loin de ces descriptions, Breitenstein *et al.* [BGG09] ont proposé une nouvelle définition pour un événement rare. Pour décrire une scène anormale, ils intègrent l'information temporelle et distinguent entre les deux termes « événement rare » et « événement inhabituel ». Van Belle [Bel08], pour sa part, considère que tout événement se produisant rarement et d'une manière similaire à une incidence de maladie (comme les tremblements de terre ou les défaillances de composants) est un événement rare. Cette définition est, en fait, basée sur une étude statistique de la production d'un événement donné dans une période de temps limitée.

En conclusion, le terme objet rare ou événement rare désigne les objets atypiques dont la fréquence d'apparition est très faible. Ces objets sont certes peu fréquents, mais aussi ils présentent des caractéristiques différentes. Ainsi, contrairement aux objets habituellement rencontrés dans une image donnée, l'apparition des objets rares peut être choquante et nécessite dans certains cas une intervention en urgence. D'un autre côté, la notion de rareté dans une image ne peut pas être définie par

des règles communes. La rareté est souvent différemment appréciée en fonction des événements rencontrés, de l'état initial et du domaine d'application. En vision par ordinateur, les objets rares peuvent avoir un fort impact et fournir des connaissances précieuses. C'est ainsi que la reconnaissance de ces objets devient de plus en plus intéressante et qu'elle fait l'objet de plusieurs travaux de recherches.

1.2.2 Défis et motivations

Cette thèse s'intéresse au problème de détection des objets atypiques dans une image donnée. Contrairement aux travaux s'intéressant à une particularité définie d'un objet rare, l'approche proposée permet de spécifier deux classes principales : « objet marquant » et « objet rare ». Par objet rare, nous désignons les objets extrêmement différents de composants habituels d'une image donnée, dont les caractéristiques les rendent très précieux. Les objets marquants sont aussi des objets d'une fréquence faible, cependant, ces objets ne nécessitent pas d'intérêt autant que les objets rares. Considérant un ensemble de données, l'objet rare apparaît avec une extrême rareté voire pas du tout. Les objets marquants, quant à eux, apparaissent plus souvent mais ils ne sont pas aussi fréquents que les objets ordinaires et peuvent dans certains cas présenter certaines particularités. D'une façon plus générale, les objets rares ont des propriétés spécifiques qui les différencient de celles de tous les autres rencontrés dans un flot de données. Contrairement aux modèles traditionnels, reliant les objets avec des caractéristiques particulières et convertissant ainsi le problème à la détection de certaines catégories d'objets, nous proposons une approche indépendante des caractéristiques, catégories ou d'autres formes de connaissance *a priori* sur l'objet. Le choix des caractéristiques appropriées, sans s'appuyer sur des informations sur chacune des classes, est important pour une approche générale de détection. Les différentes étapes de notre approche sont présentées dans le diagramme de la figure 1.1.

Tout au long de ce manuscrit, nous veillons à ce que les différentes étapes de notre modèle de détection soient mises en œuvre avec le minimum de références à des connaissances statistiques sur les images. Pour surmonter la difficulté liée aux catégories imprévues et innombrables des modèles rencontrés, nous faisons appel à la sémantique. Nous proposons un raisonnement hypothétique fondé sur les objets représentés dans un ensemble d'images et leurs fonctionnalités disponibles. La catégorisation des différentes classes d'objets (classique, marquant ou rare) est basée sur la sémantique extraite à partir de la base de données disponibles. Un système de détection de saillance visuelle est utilisé pour décider de la différenciation significative entre les deux classes : « objet marquant » et « objet rare ».

Le système proposé peut être vu comme un couplage de la vision avec la sémantique qui tient compte du contexte de l'image donnée. Notre approche ne nécessite aucune connaissance *a priori*. Cependant, une base importante d'images nous est nécessaire pour l'étape d'apprentissage.

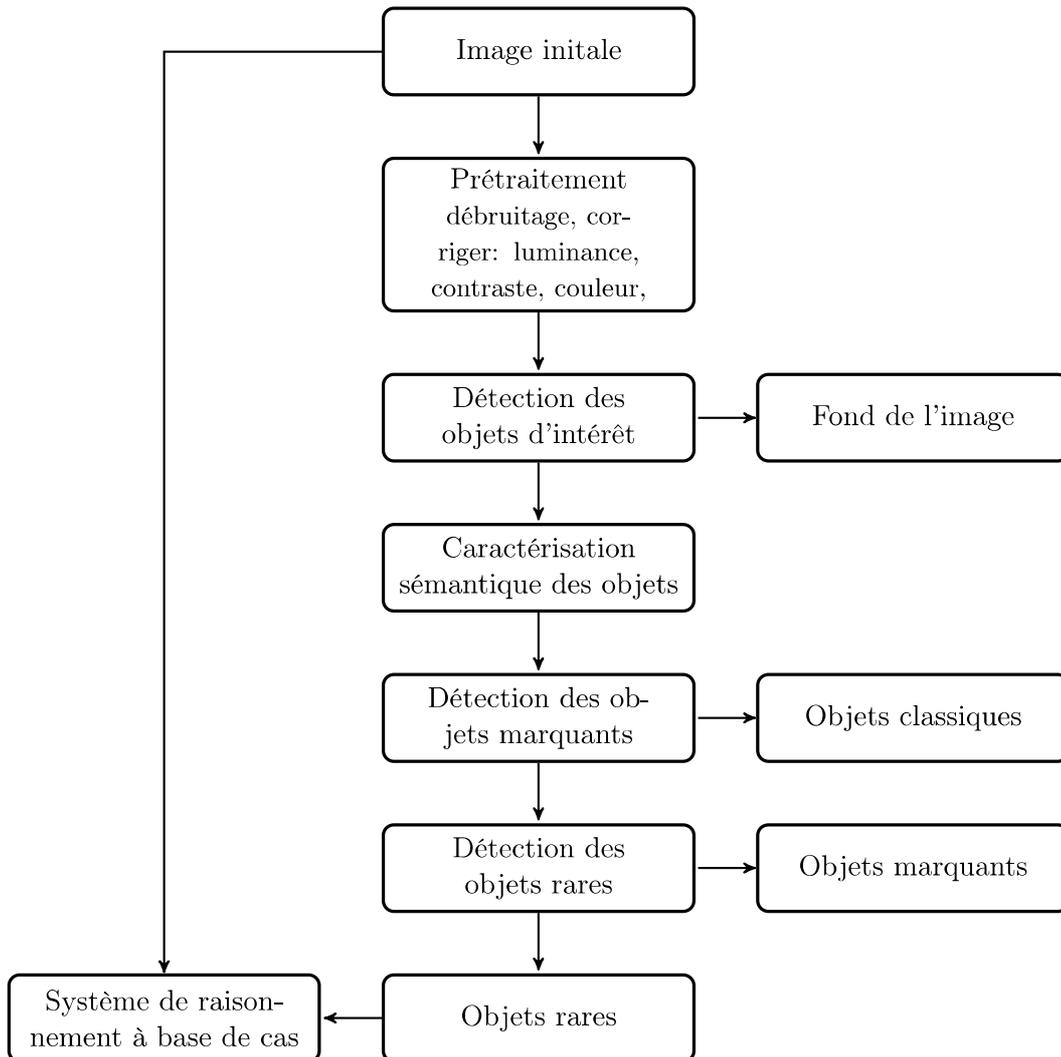


Figure 1.1: Diagramme du système de détection des objets rares dans une image donnée.

1.2.3 Problématique

Notre travail a pour objectif la détection des objets rares. Cela signifie la détection des objets atypiques dans une image donnée. Dans la littérature, les recherches s'intéressant aux approches de détection des objets rares partagées par différents domaines d'application sont presque inexistantes. La détection automatique et l'extraction de ces objets dans une image naturelle est en réalité un problème non trivial pour les raisons suivantes :

- Rareté dans le cas général : une première difficulté est l'impossibilité de donner une définition commune d'un objet rare. Comme on l'a déjà détaillé dans le paragraphe 1.2.1, la rareté est exprimée différemment en fonction des con-

stituants habituels d'une image, de son statut initial ou de la nature des objets rencontrés ;

- Absence du contexte : quand on cherche à détecter des objets cibles dans le cas général, une contrainte principale se pose c'est l'absence du contexte. Toutefois, en vision par ordinateur, tout ce qui est vu est exploité et analysé relativement à des connaissances préalables du contexte. La détection des objets cibles exige, dans la plupart des applications de traitement des images, de bien connaître les caractéristiques et la nature des informations contenues dans le signal 2D. Les propriétés générales des objets cibles dans un contexte indéfini ne sont pas susceptibles d'exister ;
- Manque d'informations : la plupart des modèles de détection se focalisent sur l'exploitation et la synthèse des propriétés des objets cibles. Considérant le cas de détection d'objets rares, ces objets sont par nature très peu présents. Or, pour une analyse pertinente, il est souvent nécessaire de disposer de beaucoup de données. Ainsi, disposant de peu ou pas de connaissances au sujet des objets rares, un vrai problème de manque d'informations se pose. Face à cette insuffisance de connaissances, on est confronté à d'autres difficultés, à savoir l'obtention d'une différenciation significative entre les objets rares et les objets classiques rencontrés, différenciation indispensable pour l'étape d'extraction. Aussi, lorsqu'on dispose de beaucoup de connaissances au sujet d'événements plus fréquents, il y a un grand risque de perdre les informations minimales concernant les objets rares ;
- Contrainte du temps : dans plusieurs cas d'applications (catastrophe naturelles, présence de mine, tumeur ou cellule cancérigène, surveillance aéroport, ..), la présence d'un objet rare est fortement liée à une caractéristique de risque. Par conséquent, ces événements font l'objet d'une détection rapide voire même une reconnaissance rapide. Cependant, lorsque l'on dispose d'une quantité phénoménale de données à traiter, on est confronté au problème de traitement de volumes d'informations importants dans un temps de calcul limité ;
- Présence du bruit : les images des scènes naturelles sont très bruitées et les objets extraits seront donc bruités. Ainsi, la présence d'un bruit dans l'image rend difficile la conception d'une méthode générale de détection des objets rares. D'autre part, la présence du bruit dans certaines images peut biaiser les résultats de détection et le bruit sera identifié comme des éventuels véritables événements d'intérêt inhabituels. Par conséquent, il y a un intérêt à éliminer ou réduire toute sorte de bruit dans le processus de détection. Dans la littérature, plusieurs travaux ont été élaborés proposant des solutions pour réduire l'importance des imperfections liées aux données bruitées. Cependant, la nature des imperfections dépend de plusieurs facteurs dont la nature de l'image elle-même et les conditions de son extraction. Ainsi, il se pose souvent un problème de connaissance de degré de bruitage des images avant de procéder à un traitement.

1.3 Les différents types d'applications

Les événements rares peuvent potentiellement se produire dans de nombreux types d'images (figure 1.2).

- Dans une image aérienne : la reconnaissance des événements rares apparents ou cachés dans des images aériennes joue un rôle important dans le domaine de l'agriculture, la gestion des forêts, la géologie, l'hydrographie, etc. Un exemple d'application possible est la gestion de l'environnement à savoir la détection des entrepôts de produits chimiques dangereux et les dépôts de pétrole. Autre exemple : la détection et la reconnaissance des objets fabriqués par l'homme dans une image aérienne. La détection automatique des objets manufacturés est importante pour la compréhension des scènes, de la navigation robotique, de la surveillance et de la cartographie. Les algorithmes développés dans ce contexte sont de plus en plus appliqués dans le domaine militaire ;
- Dans une image radar : la reconnaissance automatique des bâtiments, des terrains et des routes à partir d'une image SAR (en anglais *Synthetic Aperture Radar*) contribue dans les domaines de la recherche d'image et de la surveillance et permet la mise à jour des bases de données géographiques du système informatique ;
- Dans une image astronomique : actuellement beaucoup de recherches sont consacrées à la détection et la reconnaissance d'objets rares dans des images astronomiques. Les méthodes de reconnaissance de nouveaux types d'objets dans les images astronomiques fournissent des capacités pour aider les scientifiques à la découverte de nouveaux types d'objets astrophysiques à savoir les galaxies, les nébuleuses, les étoiles, les amas, etc, . . . ;
- Image de visage : dans les applications de détection des visages, on peut être confronté à un problème de détection d'événements rares. Dans le domaine de la sécurité, des nombreuses applications ont été développées pour la détection des fraudes et la surveillance des activités criminelles. Lorsqu'on dispose d'un grand nombre d'images issues de caméra de surveillance, l'apparition de visages en elle-même peut être considérée comme un événement rare. Dans d'autres exemples, l'apparition d'un certain type de visage ou d'une caractéristique particulière dans le visage est considérée comme un événement rare ;
- Image sonar : dans l'environnement sous-marin, la détection des objets vit depuis toujours un progrès. Beaucoup de travaux de recherche se sont intéressés au problème de la détection des objets rares dans une image sonar. La présence de mines présente des dangers pour la navigation. Dans certains autres cas, la détection des objets manufacturés comme les épaves de navires coulés ou appareils électriques ou autres objets manufacturés est considéré comme un événement intéressant et fera l'objet d'une extraction automatique ;

- Image médicale : dans le domaine de la médecine, les applications où les médecins cherchent à détecter un objet rare sont très nombreuses. Par exemple la détection, des cellules tumorales ou cellules mutantes circulant dans le sang ou la détection des tumeurs dans une base des images médicales. En biologie, l'observation au cours d'une manipulation de certaines réactions moléculaires différentes peut correspondre à un événement rare.

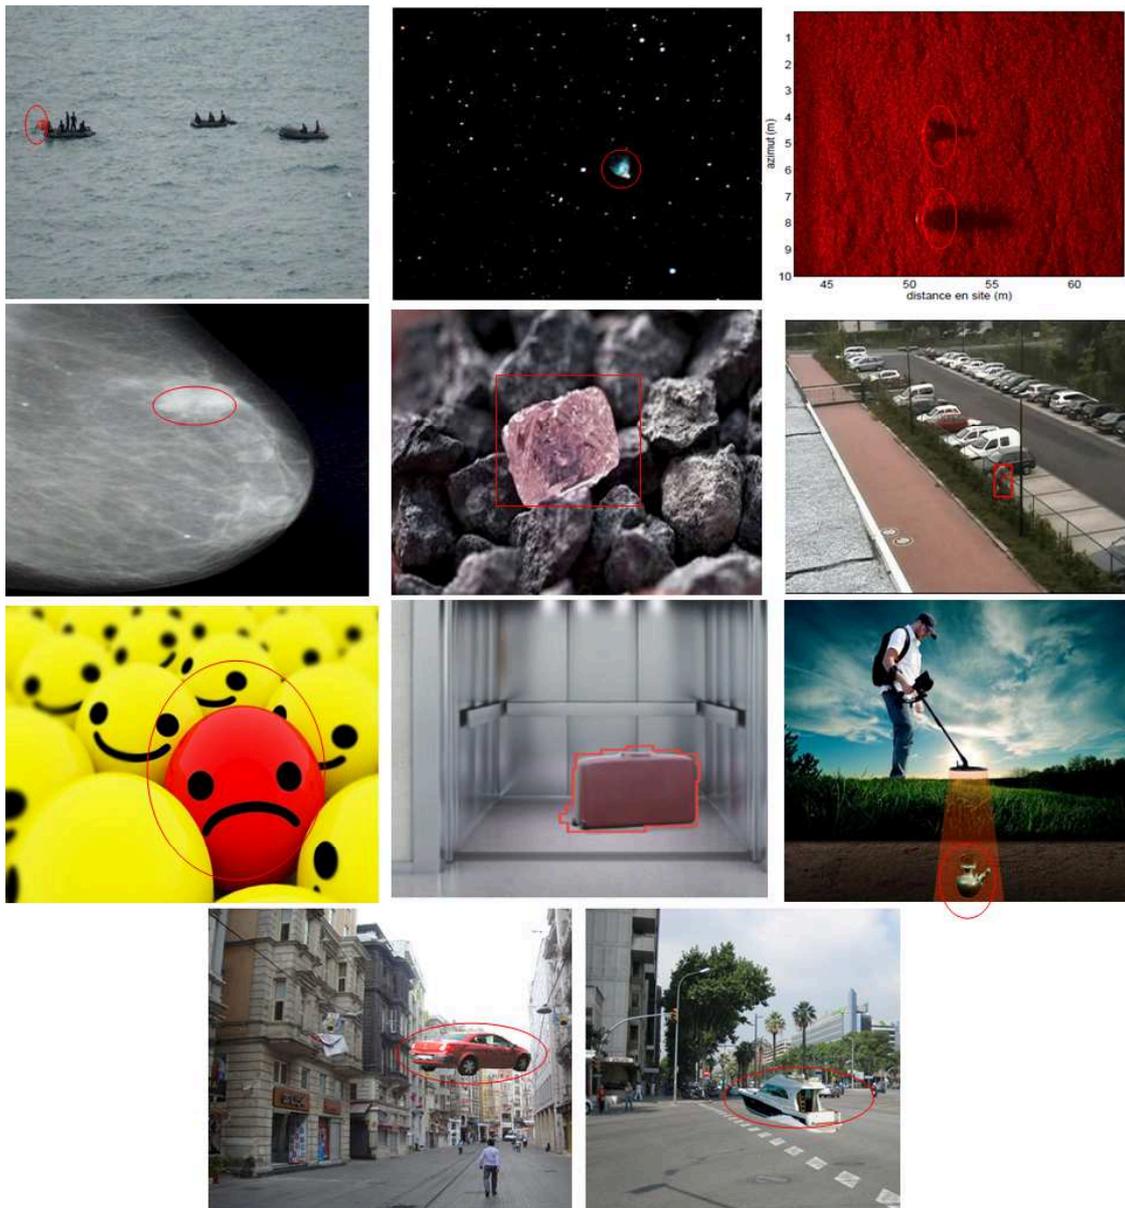


Figure 1.2: Exemples d'applications de détection des événements rares dans différents types d'images naturelles.

Les domaines d'application de la détection des objets rares dans une image naturelle sont trop nombreux pour les énumérer dans cette thèse. Nous nous contentons de la liste citée pour réaliser tous les travaux bibliographiques.

D'une manière générale, les objets rares se manifestent dans certains cas comme des opportunités à exploiter, dans d'autres cas ils présentent des risques qui peuvent s'améliorer. Ces objets sont certes de fréquence négligeable mais leur détection ou leur extraction est dans la majorité des cas d'une importance capitale.

1.4 Modélisation d'un objet rare

Plusieurs travaux de recherche se sont intéressés au problème de détection des objets rares dans une image naturelle. La détection automatique de ces objets joue un rôle important pour les étapes d'analyse et d'interprétation de l'image.

Plusieurs travaux publiés récemment se sont intéressés au problème particulier de la détection des objets manufacturés. Les méthodes développées sont largement utilisées pour l'extraction des objets artificiels dans une image aérienne ou satellitaire [RLC99].

Les algorithmes traditionnels sont basés sur les caractéristiques géométriques, le modèle fractal, le modèle probabiliste et le niveau de gris [DRW79]. B.Manderlbort [Man82] a proposé un modèle de détection des objets manufacturés basé sur la caractéristique fractale. L'idée pour détecter ces objets est essentiellement extraite de la proposition suivante : comparés aux objets manufacturés, les objets naturels ont des formes irrégulières et sont souvent des objets fractals. Dans [MA84] la classification des objets manufacturés est basée sur le calcul de la dimension de Hausdroff-Besicovich et les dimensions topologiques de l'objet. D'une manière analogue, B.E. Cooper [BDJ94] a utilisé la métrique d'erreur fractale comme une mesure permettant de discerner les objets manufacturés. En supposant que les caractéristiques d'une image naturelle sont mieux ajustées par le modèle de mouvement brownien fractionnaire (FBM), Cooper dans son approche calcule la courbe d'ajustement de son modèle pour une caractéristique donnée.

Guo Cao *et al.* proposent une approche similaire basée sur le modèle modifié de Mumford-Shah [CYZ05b]. Dans leur travail, ils se servent d'une stratégie de "l'évolution de la courbe en deux étapes" pour obtenir une meilleure détection. Ensuite, ils appliquent la mesure de l'erreur fractale dans le premier niveau de la courbe d'évolution [BDJ94]. Leur méthode permet d'éviter d'une manière astucieuse la sélection d'un seuil pour discriminer l'erreur fractale de l'image.

Outre les propriétés fractales, des travaux de recherche considèrent la couleur, la texture et les caractéristiques géométriques [For97] pour marquer les objets rares. Bien que ces approches s'intéressent à l'extraction et l'identification des objets atypiques, elles restent néanmoins spécifiques à des types particuliers d'objets.

Ruiz *et al.* ont proposé dans [RLC99] une nouvelle technique pour la classification des objets basée sur un ensemble des caractéristiques dérivées de la distribution de la forme et du niveau de gris des objets dans chaque niveau de l'image. M.J.Carlottp *et al.*, de leur part, supposent dans leur travail [CS90] que les objets rares sont des entités fabriquées avec des formes géométriques simples ayant de grandes surfaces

et des couleurs unies.

Récemment, Y. Caron *et al.* [CMV02] décrivent une méthode basée sur la distribution statistique de motifs de texture dans les images en niveaux de gris. Contrairement aux méthodes basées sur la détection de contour, ils recourent à la loi de Zipf [Zip49] pour calculer la fréquence des éléments dans un ensemble de symboles et déterminer les régions de l'image qui contiennent l'intensité la plus uniforme. En fait, selon leur travail, la présence d'un objet atypique modifie la distribution des fréquences des modèles d'occurrence calculée en utilisant la loi de Zipf dans la région contenant l'objet. Leur méthode est complètement indépendante de la forme de l'objet. En supposant que les objets manufacturés sont caractérisés par une structure linéaire, Sanjiv Kumar *et al.* dans [KH03a] ont étudié les lignes et la dépendance des bords dans des différents niveaux de l'image pour identifier les objets de forme régulière. Une approche similaire de la modélisation d'objets rares, a été proposée par Foresti *et al.* dans [FMRT97] en considérant le codage de chaque forme de contour des objets rencontrés dans l'image. L'algorithme proposé examine la présence des lignes droites pour juger de la présence des objets rares. Différemment, certains travaux considèrent la distribution de Weibull pour identifier les objets manufacturés. Selon ces recherches, les régions contenant des objets atypiques ont des valeurs de paramètres de Weibull inférieures à celles contenant des objets naturels. Par exemple dans l'approche proposée par Mark J. Carlotto dans [Car96], la méthode d'extraction est basée sur l'appariement de l'histogramme local par une famille de densités de Weibull.

Récemment, le processus de détection des objets rares se base essentiellement sur des algorithmes d'identification des anomalies dans une grande base des données. Certaines méthodes se servent du concept de la normalité et de la notion du plus proche voisin [ME05, ZSV04]. A. Soto *et al.* [SCZ05] ont proposé la création d'un outil informatique permettant la détection de types rares dans des images astronomiques. Suite à l'observation d'un grand ensemble de données, le système permet l'apprentissage d'un modèle probabiliste pour les différents objets dans la base de données. Les étoiles et les galaxies atypiques sont au final présentées par le modèle défini et montrent une faible vraisemblance comparativement aux observations usuelles. D'autres études récentes ont exploité les méthodes de la saillance visuelle pour identifier les objets non usuels [WIR⁺02, TG80]. Dans leur travaux, les auteurs considèrent que tout objet qui "saute aux yeux" ("*pop up*") dans la phase de pré-attention est un objet rare [HHN06].

Inspirés par des travaux antérieurs sur la détection de la cible basée sur l'attention visuelle, Jun Yang [YZW07] a proposé une nouvelle méthode d'attention basée sur un algorithme « level set » pour extraire les régions manufacturées. Li *et al.* dans [LLL06] ont développé une méthode de segmentation de terrain en utilisant le spectre et la saillance visuelle. En exploitant les méthodes de la perception visuelle humaine, Fei Cai [CCM11] a proposé une nouvelle approche de détection des objets marquants pour l'extraction de la texture et de la structure géométrique. La méthode utilise le spectre logarithmique et le spectre résiduel pour marquer le prototype des objets. Généralement, les modèles de détection de saillance sont indépendants des caractéristiques, catégories ou autres formes de connaissances préalables sur l'objet. Cependant, vue l'immense quantité de catégories de modèles visuels, le

développement d'un système de détection de saillance robuste demeure nécessaire.

1.5 Détection générale d'un objet

Depuis longtemps, la détection des objets présente un domaine de recherche très actif dans la vision par ordinateur. En fonction des connaissances disponibles pour traiter un sujet donné, on distingue deux différents types de détection : la détection générale et la détection spécifique des objets [CdFB04]. Dans la littérature, les méthodes spécifiques s'intéressant à un certain type d'objets sont très abondantes. Dans la majorité des cas, ces méthodes sont simples et se basent sur des caractéristiques particulières de l'objet recherché. La reconnaissance générique sans connaissance *a priori* sur le contexte de l'image est par contre un des challenges des travaux de recherches dans le domaine de traitement d'images. La reconnaissance générique de l'objet peut être définie comme le processus de catégorisation des objets individuels. Bien que l'être humain soit par nature très performant dans les tâches de catégorisations, le problème de catégorisation des objets n'a été abordé que très récemment. Une approche de catégorisation d'objets a été introduite par Dorkô et Schmid [DS03]. Elle est basée sur la construction et la sélection des segments d'objet à des échelles invariantes. Ces segments sont utilisés pour l'apprentissage des données. L'approche proposée [DS03] permet d'obtenir des résultats performants et une détection robuste vis-à-vis de changements d'échelle et les variations dans les conditions d'observation. Une autre approche de description des objets pour la catégorisation a été introduite par Thureson et Carlsson dans [TC03]. Elle est basée sur le calcul des indices et la forme de l'histogramme des images de la base de données. Ces indices sont calculés en considérant des paramètres de localisation et le gradient de direction des échantillons. L'étape de catégorisation des images est réalisée en calculant la distance entre le vecteur représentatif de toutes les images de la base et l'histogramme de l'image considérée. Un nouveau système de catégorisation des objets a été proposé par Andreas Opelt *et al.* dans [OPMFA06]. Leur travail est basé sur une approche d'apprentissage des objets dans des images fixes. L'approche proposée permet l'utilisation des ensembles flexibles des descripteurs et des catégories d'objets. Les objets sont reconnus même lorsqu'ils sont présentés à des échelles différentes ou captés à partir des différents angles de vues sur des fonds très texturés. Une autre possibilité d'application des méthodes de détection générale des objets c'est celle des modèles déformables. Un exemple d'application est présenté dans [FMR08]. L'idée pour détecter les objets du modèle déformable se base sur l'utilisation de plusieurs types de filtres et une fenêtre coulissante. Le modèle est basé sur un filtre principal et plusieurs autres filtres secondaires. Il permet la détection des objets à différentes échelles et différents rapports de forme. Une amélioration des performances de ce modèle de détection générique de l'objet a été proposée dans [SCH⁺11, WBLL11]. Le problème de catégorisation des objets est aussi discuté dans d'autres travaux comme par exemple la tâche de classification binaire à savoir la distinction entre la classe de l'objet et la classe de fond [AAR04, HSMP01, PP00]. Ces travaux utilisent, d'une manière alternative, des détecteurs des points d'intérêt pour marquer des fenêtres locales qui seront classées par la suite soit comme un objet ou

comme une partie d'un objet. Dans les deux cas, le classificateur est appliqué à un grand nombre d'emplacements de l'image. Par contre, ces approches présentent une faiblesse liée au taux élevé de fausses alarmes.

Les travaux de recherches et les différentes contributions qui ont abordé ce problème de la reconnaissance générique des objets dans l'image sont très différents. Néanmoins, l'idée commune de ces approches est d'utiliser des bases de données d'images pour découvrir les objets d'intérêt.

1.6 Extraction des connaissances et sémantique des images

De nos jours, la recherche en traitement d'images s'intéresse aux méthodes d'extraction d'informations et de la reconnaissance des éléments qui constituent l'image. La recherche des objets rares dans une base des données implique une extraction automatique des connaissances et un processus de fouille des données dans l'image. L'extraction des connaissances et la fouille des données permettent une caractérisation implicite des données, des relations entre les données d'image et d'autres motifs qui pourraient ne pas être stockés d'une manière explicite dans les images. L'enjeu fondamental est de déterminer comment une représentation des pixels d'une image ou une base des images peut être efficacement traitée pour identifier la sémantique de l'image. Dans ce qui suit, nous allons introduire le processus d'extraction de connaissances à partir de bases de données. Ensuite, nous présenterons la sémantique dans l'image et les principaux travaux connexes.

1.6.1 Extraction des connaissances à partir d'une base de données

1.6.1.1 Processus d'extraction des connaissances à partir d'une base de données

L'extraction de connaissances à partir de bases de données permet de transformer l'ensemble des données de la base en connaissances. Fayyad [FPSSU96] a proposé le processus d'Extraction de Connaissances à partir des Données (*ECD*) (en anglais *Knowledge Discovery from Databases (KDD)*). Il a défini ce concept comme « un processus non trivial de découverte des modèles valides, nouveaux, potentiellement utiles, compréhensibles à partir de données ». Ce processus a pour objectif la production de nouvelles connaissances qui seront validées et facilement interprétées par l'utilisateur. Le processus défini par Fayyad est générique et a été appliqué dans différents travaux de recherches. Dans la plupart de ces travaux, on peut recenser les étapes suivantes : la sélection de données, le prétraitement de données, la fouille de données et l'évaluation et l'interprétation des résultats comme le montre la figure 1.3.

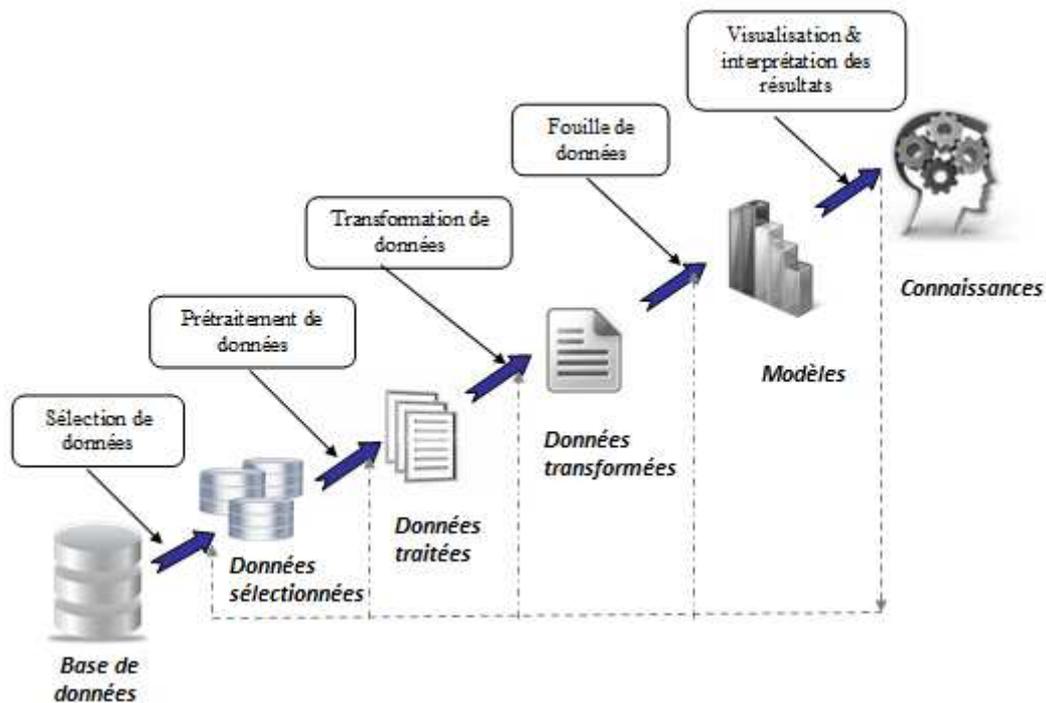


Figure 1.3: Processus d'extraction de connaissances à partir d'une base de données.

1.6.2 Étapes d'extraction de connaissances à partir d'une base de données

Les principales étapes du processus ECD sont définies d'une manière générale comme suit:

- La sélection de données : cette étape a pour objectif de définir l'ensemble des données à étudier parmi la collecte des données. Les données d'intérêt seront utilisées pour l'extraction des connaissances visées. La sélection de données permet de procéder au niveau approprié dans le processus d'extraction de connaissances à partir des données de bases. La sélection de données permet également d'analyser le problème de recherche et les méthodes à utiliser dans les étapes postérieures du processus ECD. Au niveau de cette étape, des règles, des graphiques et des structures hiérarchiques peuvent être définis sur les variables pour extraire des séquences voire même construire des nouveaux types de données. Le processus d'extraction des connaissances se base fortement sur les résultats de cette étape;
- Le prétraitement : en raison de la forte possibilité de présence de différents types de bruits dans les images naturelles, il est nécessaire d'appliquer une approche de prétraitement sur les ensembles de données collectées [Sim96, HK06]. Au cours de cette étape, les données sélectionnées sont nettoyées et traitées.

On parle ici des possibilités de remplissage de valeurs manquantes, de lissage de données bruitées, de suppression de valeurs aberrantes et d'une éventuelle résolution des incohérences. Les données peuvent également être filtrées en appliquant des filtres spécifiés par l'utilisateur. Dans de nombreuses applications de l'imagerie aérienne ou spatiale, la résolution de l'image peut varier selon les échelles d'acquisition des données donc une approche d'interpolation peut être appliquée à ce stade de préparation de données;

- La transformation : cette étape permet de définir les structures optimales de représentation de données. Elle est également connue sous le nom "consolidation de données". Au cours de cette phase, les données sélectionnées sont transformées en formes appropriées pour être exploitées dans l'étape suivante (la fouille de données)[Sim96]. Des méthodes de regroupement et de normalisation sont utilisées pour regrouper les variables et les adapter avec les méthodes de fouille de données. Lorsque le volume des données à analyser est très grand, la transformation des données se base sur des méthodes de réduction de données (telle que l'analyse en composantes principales) pour résumer le contenu de données et réduire leur format;
- La fouille de données : c'est l'étape cruciale dans le processus d'extraction de connaissances à partir d'une base des données. La fouille de données permet d'extraire des connaissances implicites et d'établir les relations entre les différentes variables. Le rôle essentiel de cette étape réside dans l'établissement de la relation entre la représentation bas niveau des pixels et l'information haut niveau des différents objets dans l'image ou dans un ensemble d'images [HK06]. Dans les travaux de vision par ordinateur et de traitement d'images, diverses techniques des domaines existants sont également appliquées pour la fouille des images; entre autres on peut citer la reconnaissance d'objet, l'apprentissage, le *clustering*, la classification et plusieurs autres applications [Bur01].

Selon le but de l'exploitation du contenu de l'image, les intervenants dans le secteur de fouille de données ont classé les méthodes de fouille de l'image en deux classes principales. La première classe concerne les méthodes spécifiques dont le but est l'extraction des caractéristiques les plus pertinentes dans la base de l'image. Le deuxième type d'approches englobe l'ensemble des méthodes de recherche et d'extraction de l'information générale dont l'objectif est la génération des modèles caractéristiques permettant de définir l'interaction entre les perceptions humaines de haut niveau et les caractéristiques bas niveau de l'image;

- L'interprétation et l'évaluation des résultats : c'est la phase finale du processus d'ECD. L'évaluation des performances est une étape critique durant laquelle les modèles représentatifs des données intéressantes dans l'image sont identifiés en se basant sur les mesures spécifiées dans la phase de fouille de données. Dans la littérature, plusieurs mesures ont été proposées pour interpréter et évaluer les résultats du processus d'ECD, parmi lesquelles nous citons : la mesure de Piatetsky-Shapiro [PS91] et la J-Mesure de Smyth et Goodman [SG91]. Ces

deux critères seront détaillés ultérieurement dans la suite de ce manuscrit. Des techniques de visualisation sont au final utilisées pour aider l'expert à comprendre et à interpréter les résultats obtenus.

1.6.3 La sémantique dans l'image

Dans les travaux de détection et recherche des objets dans l'image, de nombreuses fonctionnalités ont été proposées pour la caractérisation des images. Afin de comprendre une image, un système informatique se base généralement sur l'information donnée par le pixel de l'image. La plupart des travaux de recherches sont basés sur l'utilisation des primitives visuelles telles que la couleur, la forme, la texture et des caractéristiques spatiales. Ces caractéristiques sont généralement extraites directement à partir des représentations numériques des objets dans la base de données et sont appelées des primitives de bas niveau. Une révision complète des primitives de bas niveau peut être trouvée dans [RH99]. Une analyse de l'image, basée sur le bas niveau, n'est nullement influencée par la présence ou l'absence des objets dans la scène, ni par le lien entre la scène et l'observateur. Par conséquent, il peut y avoir plusieurs descriptions, largement indépendantes et donc insignifiantes. Par exemple, si l'on regardait une image d'une chaise dans une salle, les descriptions de bas niveau décrivent de manière explicite où les bords de la chaise étaient, où les reflets spéculaires étaient sur la surface de la chaise, ce que les couleurs sur la chaise étaient. Comme cette description est toujours liée à une image, ces descriptions seraient applicables partout dans l'image, et pas seulement à la chaise. Les humains, par contre, ont la capacité de comprendre une image dans son ensemble à un niveau supérieur d'abstraction. L'homme, par sa constitution, son éducation, l'apprentissage de la vie, sa volonté de survie et par d'autres facteurs, est capable d'extraire le contenu sémantique dès la première visualisation de l'image. Les objets qui lui apparaissent dans l'image sont de sémantique de haut niveau. Depuis de nombreuses années, la sémantique de l'image est devenue un domaine de recherche en pleine expansion. Par définition, le terme sémantique signifie l'étude scientifique de la signification. Un espace sémantique est un espace où chaque dimension représente un concept visuel significatif. La sémantique est alors introduite lorsque toutes les décisions de reconnaissance sont effectuées. Elle exige des techniques, des outils particuliers et des méthodes scientifiques. Un problème majeur pour la description de haut niveau du contenu de l'image en vision par ordinateur est la difficulté d'intégration d'une description sémantique liée au domaine.

1.6.4 Fossé sémantique et travaux connexes

Dans la littérature, l'absence de correspondance entre le signal visuel extrait des machines et celui de haut niveau de l'interprétation conceptuelle humaine d'images crée deux types de fossés : le fossé sensoriel et le fossé sémantique (voir Figure 1.4).

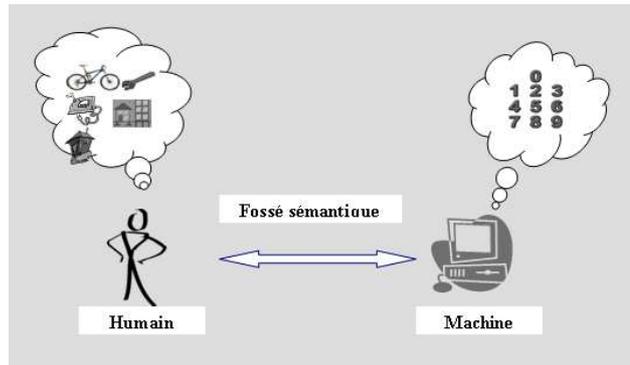


Figure 1.4: Fossé sémantique : écart de description du contenu de l'image en vision par ordinateur et chez l'être humain.

Le fossé sensoriel concerne l'écart entre le monde observé et l'image acquise. Smeulders *et al.* [SWS⁺00] ont défini le fossé sensoriel comme « L'écart entre les objets du monde réel et l'information apportée par une description informatique dérivée de l'enregistrement de l'image ».

Ce fossé intervient donc dans l'étape de l'acquisition de l'image. L'écart sensoriel est en réalité comparable au problème de la vision : comment peut-on donner un sens à une scène 3D à partir de nombreuses projections 2D de cette scène?. Les systèmes de recherche des image par contenu CBIR (*Content Based Image Retrieval*) traitent habituellement ce problème de la même façon que le système visuel humain (HVS), comme suggéré par Helmholtz et ses collègues dans [Pal99].

Le fossé sémantique est défini comme « le manque de correspondance entre l'information que l'on peut récupérer du contenu des données visuelles et l'interprétation que l'on peut en faire dans une situation déterminée. » [SWS⁺00]. Une autre formulation est l'absence du lien direct entre les concepts de haut niveau et les caractéristiques de bas niveau [LZLM07]. Comparé au fossé sensoriel, le fossé sémantique est le plus difficile à traiter. Plusieurs travaux de recherche se sont intéressés récemment à réduire le fossé entre les objets étiquetés et la sémantique. Ordonez *et al.* [OO99] se sont servis des règles d'associations pour une description sémantique des images. Ils introduisent la notion de tâches (traduction de blobs) pour segmenter l'image de synthèse. Une tâche est définie comme « des régions de pixels connexes cohérentes au niveau de la similarité de couleur et de texture ». Les règles d'associations sont donc exprimées en fonction de la dispersion des tâches de l'image. Sur le plan sémantique, l'algorithme d'Ordonez est jugé faible bien qu'il présente des résultats compétitifs. Hare *et al.* [HLES06] proposent de diviser le fossé sémantique en deux parties : l'écart entre les descripteurs et les étiquettes d'objets et l'écart entre les objets étiquetés et la sémantique complète de l'image. Les deux parties permettent de réduire l'écart de données de réponse. Afin de combler le fossé entre les descripteurs et les objets étiquetés, le système proposé permet la définition des différentes combinaisons de descripteurs permettant de représenter des objets. On parle ici d'un marquage automatique de contenu de l'image [HLES06] ou le marquage de

l'image [YjZ12].

Une autre approche permettant de réduire le fossé entre les objets étiquetés et la sémantique est l'utilisation des ontologies. Les ontologies sont une spécification explicite d'une conceptualisation (Gruber, 1995[Gru95]) permettant une représentation formelle des concepts et des relations d'un domaine scientifique. Pour surmonter le problème du fossé sémantique, les ontologies peuvent être utilisées pour définir des concepts de haut niveau [LZLM07, HLES06]. En fait, les ontologies sont considérées comme un terrain intermédiaire de représentation entre le monde de l'image et le monde de la connaissance experte. La figure 1.5 illustre la manière dont l'information de l'image pourrait prendre. Il s'agit d'une forme basée sur les ontologies (à gauche), de même que la connaissance de l'expert (à droite).

Dans les ontologies de l'objet, une définition qualitative de la sémantique de haut niveau peut être donnée par exemple en fonction de la couleur, la position, la taille et la forme. La réduction de l'écart utilisateur-détecteur dépend en fait du type d'utilisateur, des données de recherche et des modalités des requêtes et des interrogations [9]. Hassan *et al*, dans [HHP09] ont proposé des ontologies permettant de définir les paramètres de l'algorithme de segmentation et les étiquettes potentielles des régions. La description des concepts de l'ontologie est basée principalement sur des caractéristiques géométriques. Les segments sont en fait ajustés de manière à se rapprocher de leur description dans l'ontologie. Hudelot *et al*. [HAB08] ont conceptualisé des relations spatiales floues dans des ontologies afin d'identifier des organes dans des images médicales. Durand *et al*. ont utilisé dans leur ontologie la radiométrie des objets pour définir les relations spatiales dans les images satellitaires.

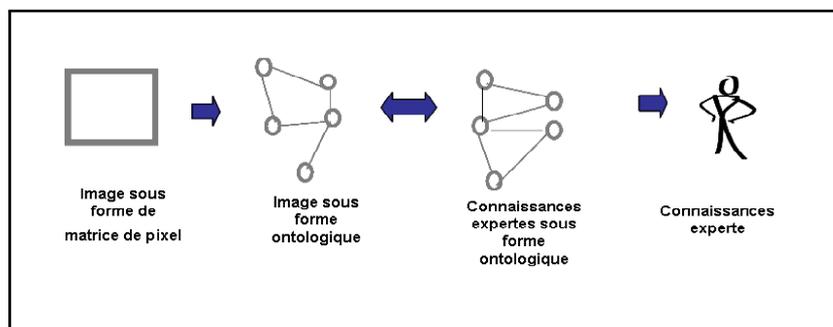


Figure 1.5: Description du concept de l'ontologie : relation intermédiaire entre l'image et la sémantique.

1.7 Conclusions

Le terme "objet rare" est très largement utilisé en sciences cognitives. Cependant, sa signification est loin d'être homogène et consensuelle. L'algorithme de détection des objets rares que nous allons proposer, permet de classer les objets d'une scène donnée en trois classes : "objet habituel", "objet marquant" et "objet rare". Dans la suite de notre travail, nous détaillerons les différentes approches de détection, les

méthodes utilisées et les résultats obtenus ainsi que nos contributions.

Considérant la nature bruitée de l'image naturelle, nous étudierons dans le chapitre suivant l'étape de prétraitement.

Prétraitement des images naturelles : Application au cas des images sonars

Sommaire

2.1	Introduction	27
2.2	État de l'art : le bruit dans une image naturelle	27
2.2.1	Débruitage des images : sources et types de bruit	27
2.2.2	Autres éléments à corriger dans une image bruitée	30
2.3	Débruitage des images par filtrage	31
2.3.1	Filtrage spatial	31
2.3.2	Filtrage fréquentiel ou spectral	33
2.3.3	Le filtre homomorphique	34
2.4	Exemple de prétraitement d'une image naturelle : cas d'une image sonar	35
2.4.1	Prétraitement d'une image sonar	36
2.4.2	Rehaussement homomorphique des images	37
2.5	Définition de critères d'évaluation de la méthode de filtrage	39
2.6	Modélisation statistique et estimation des paramètres	44
2.6.1	Modélisation par la loi normale	44
2.6.2	Modélisation par la loi de Rayleigh	46
2.6.3	Modélisation par la loi de Weibull	46
2.7	Évaluation des performances des modèles statistiques	47
2.8	Tests d'hypothèse et analyse des résultats obtenus	48
2.9	Tests de normalité : méthodes empiriques et graphiques	50
2.9.1	Indicateur de normalité	50
2.9.2	Le Q-Q plot et la droite de Henry	50
2.10	Conclusions	52

2.1 Introduction

Le prétraitement des images est l'ensemble des opérations effectuées sur une image pour l'améliorer. D'une manière générale, ces prétraitements visent à supprimer l'information gênante et inutile dans l'image en vue d'un traitement ultérieur. Ce chapitre présente les principales sources et types de bruit dans une image naturelle. Nous présenterons brièvement les méthodes basées sur le filtrage en passant par les principaux types de filtres. Puis nous aborderons le filtrage homomorphique et nous terminerons en détaillant notre approche de prétraitement. Les différents tests expérimentaux sont réalisés sur des images sonars. Nous discutons alors les différentes étapes de prétraitement de l'image sonar.

Ce chapitre trace les principales contributions de l'utilisation du filtre homomorphique, de l'amélioration des images, du renforcement des contrastes et de l'évaluation de la procédure de prétraitement.

2.2 État de l'art : le bruit dans une image naturelle

2.2.1 Débruitage des images : sources et types de bruit

Le débruitage d'images a pour objectif de corriger les différentes distorsions introduites dans l'image. D'une manière générale, le processus de débruitage inclut l'ensemble des opérations effectuées sur une image en vue de réduire ou supprimer le bruit qui lui a été ajouté.

Le but final de débruitage est de retourner une image résultat qui soit la plus proche possible de l'image originale c'est-à-dire avant qu'elle ne soit altérée.

Typiquement, un algorithme de débruitage d'images implique un compromis entre la réduction du bruit indésirable et la préservation du maximum d'informations importantes dans l'image.

2.2.1.1 Sources de bruit

Le bruit est généralement introduit lors de l'acquisition ou la transmission de l'image dans un système de traitement des données. Ainsi, plusieurs sources de bruit sont à l'origine de bruitage des images naturelles. Les principales sources de bruit dans une image numériques sont :

- Bruits liés aux capteurs de l'image : par exemple le bruit issu de l'interférence dans le canal de transmission de l'appareil de capture de l'image ;
- Bruits liés aux conditions environnementales : par exemple insuffisance de la lumière, présence de la poussière sur l'objet à capturer, perturbations du milieu (nuages, humidité, brouillard, etc.), perturbations électromagnétiques (qui peuvent influencer directement sur le capteur) ;
- Bruits liés aux conditions d'acquisition de l'image par exemple mouvement de la scène ou du photographe) ;

- Bruits liés à la numérisation du signal par exemples l'échantillonnage ou la quantification d'images.

2.2.1.2 Types de bruit

Le bruit affectant une image naturelle est fortement lié au système d'acquisition et à la procédure de transmission de l'image. Selon le type d'application, les images peuvent être acquises par différents systèmes tels que l'Imagerie par Résonance Magnétique (IRM), l'échographe, Mammographe, Radar à Synthèse d'Ouverture (RSO), Sonar Latéral (SL), Sonar à Synthèse d'ouverture (SAS), etc.

Les types de bruits qui affectent les images sont alors très nombreux et variés. Selon leur caractéristiques, on peut distinguer trois classes de bruit: Bruit impulsionnel, bruit additif et bruit multiplicatif.

La figure 2.1 présente l'effet de bruitage de l'image Lena par ces différents types de bruit.



(a) Image non bruitée



(b) bruit impulsionnel



(c) Bruit additif gaussien ($\sigma = 20$)



(d) Bruit multiplicatif

Figure 2.1: Application des différents types de bruit sur l'image de Lena.

2.2.1.3 Bruit impulsionnel

Le bruit impulsionnel (appelé aussi bruit « poivre et sel ») est un bruit qui assigne à un certain nombre de pixels de l'image une valeur de niveau de gris aléatoire. La valeur des pixels bruyants est donc totalement non corrélée avec la valeur du même pixel dans l'image initiale. Ce bruit peut être dû soit à des erreurs de transmission des données, soit à la présence des particules sur le capteur d'images, soit aux changements brusques et soudaines de signal de l'image.

2.2.1.4 Bruit additif

Le bruit additif est obtenu lorsqu'une valeur aléatoire est ajoutée à la valeur de chaque pixel initial. Dans le cas d'un bruit additif, le problème de débruitage peut être posé mathématiquement comme suit:

$$A = B + N \quad (2.1)$$

Avec A est l'image bruitée, B est l'image originale et N est le bruit ajouté. Le bruit gaussien est l'exemple le plus connu du bruit additif. Pour ce type de bruit, chaque pixel de l'image bruitée est défini comme la somme de la valeur de pixel réelle et une valeur aléatoire de bruit issue d'une distribution gaussienne.

Contrairement au bruit impulsionnel, lorsque l'image est corrompue par un bruit additif, la valeur du bruit est complètement indépendante de l'intensité de valeur de pixel.

2.2.1.5 Bruit multiplicatif

Le bruit multiplicatif est un bruit dépendant de signal dont l'amplitude est calculée en fonction de la valeur initiale de chaque pixel de l'image.

L'équation 2.2 décrit une forme simple que peut prendre un bruit multiplicatif en supposant : B une image non bruitée et A la même image avec un bruit multiplicatif N . Alors, chaque pixel j est caractérisé par la relation:

$$A_j = B_j \cdot N_j \quad (2.2)$$

où N_j est une variable aléatoire de moyenne égale à 1.

La principale caractéristique de ce bruit est que les pixels d'une zone homogène seront d'autant plus bruités que leur niveau de gris est élevé. D'une manière générale, le bruit multiplicatif est dû aux photons de prise de l'image. En effet, pendant un temps d'exposition donné, seul un nombre fini de photons peuvent atteindre le capteur de l'image. Ce bruit est fortement lié à la lumière et il est présent dans la plupart des images enregistrées sur des films diapositives ou captées par le radar à ouverture synthétique (SAR)[Lee81].

Un exemple de ce type de bruit est le bruit de *speckle* ¹.

¹Le speckle est un bruit multiplicatif pratiquement présent dans toutes les images sonars. Ce bruit est dû à une sommation des échos situés à des distances légèrement différentes les uns des autres par rapport au sonar. D'un point de vue statistique on obtient une sommation dont le résultat en terme d'amplitude répond à une loi de Rayleigh qui se traduit sur l'image par cet aspect "sableux".

2.2.2 Autres éléments à corriger dans une image bruitée

Outre les problèmes liés au bruit, les images peuvent souffrir de faibles contrastes, d'une faible luminosité, des couleurs atténuées ou altérées et d'une visibilité réduite. Dans ce qui suit, nous allons présenter ces problèmes et les approches habituellement appliquées pour les corriger ou les améliorer.

- Rehaussement du contraste : lorsque l'éclairage d'une image donnée est très faible ou non homogène, il peut y avoir des pertes de contraste. Cependant, quand on dispose de l'information sur la nature de perte en contraste, le rehaussement peut être réalisé d'une façon locale ou globale. Plusieurs méthodes ont été développées pour corriger ce problème. Les méthodes de l'égalisation d'histogramme [PAA⁺87, KKH01] sont les plus connues pour le rehaussement du contraste. Étant donné que l'histogramme des images ayant un faible contraste occupe une petite portion de la plage des intensités, ces méthodes permettent d'étaler l'histogramme sur une plus grande plage. D'autres méthodes comme la Retinex (en anglais *Single Scale Retinex SSR*) et la MSR (*Multi Scale Retinex*) ont été développées pour corriger le contraste des images. Ces méthodes ont pour principe d'appliquer des opérations non linéaires sur l'image initiale afin de construire une nouvelle image éclairée par une lumière blanche et constante [JW95].
- La luminance : un autre problème de prétraitement des images est la non uniformité de la luminance. La luminance est définie comme l'intensité lumineuse par unité de surface dans une direction donnée. Lorsque l'éclairage est non uniforme, ou que les conditions d'éclairage ne sont pas bonnes, des ombres profondes pourraient être introduites dans l'image et biaiser son contenu. Dans les travaux de traitement d'image, il existe plusieurs méthodes permettant le rehaussement de la luminance de façon locale ou globale. Parmi ces méthodes, on trouve encore les méthode d'égalisation d'histogramme et les méthodes de filtres à rang (en anglais *rank filters*).
- Image floue : plusieurs méthodes de prétraitement sont appliquées pour réduire le flou dans l'image. Par exemple, pour corriger les défauts résultant du mouvement de rotation, des filtres bien spécifiques (filtres d'aiguisement) peuvent être utilisés pour améliorer les caractéristiques de pointe.
- Correction des couleurs : lorsque les images ne sont pas prises à l'air libre et sont issues de milieux différents, il peut y avoir une atténuation importante des couleurs. Cette atténuation est due généralement, d'une part à la quantité d'énergie absorbée par le milieu, et d'autre part à la partie de la lumière diffusée dans d'autres directions que celle de l'observateur. Dans la phase de prétraitement de l'image, il peut être utile de redistribuer la couleur et de corriger les artefacts d'illumination. Typiquement, la teinte de couleur est l'un des attributs les plus difficiles à corriger.

Dans notre présent travail, nous ne traiterons que des images à niveaux de gris et ne considérerons pas le cas des images colorées.

Durant la phase de prétraitement de l'image plusieurs autres problèmes devraient être corrigés avant qu'on ne procède aux étapes postérieures du processus de traitement. Ces problèmes dépendent fortement de la nature des milieux, des conditions de captures et plusieurs autres facteurs qui dépassent les objectifs de notre thèse.

Les approches standards permettant le prétraitement de l'image ont été synthétisées et discutées par Gonzalez dans [GW07]. Le filtrage est la méthode la plus utilisée pour le débruitage des images. Dans la suite, nous discutons brièvement du processus de filtrage et les différentes approches utilisées dans l'étape de prétraitement.

2.3 Débruitage des images par filtrage

D'une manière générale, l'opération de filtrage consiste à remplacer un pixel donné par une autre valeur dépendante de son voisinage. Le processus de filtrage permet ainsi de diminuer l'amplitude des perturbations liées au bruit tout en préservant et accentuant les zones de transitions. Dans le domaine de traitement des images, les filtres sont utilisés pour éliminer le bruit d'une image tout en préservant l'image originale. Le processus de filtrage permet d'effectuer également la réduction de bruit, l'interpolation et l'échantillonnage des données et plusieurs autres tâches. Le choix idéal du filtre dépend ainsi de la nature de la tâche à effectuer par le filtre et du type de données.

On distingue plusieurs types d'approches de filtrage. Ces approches peuvent être classifiées en deux groupes :

- Approches de filtrage spatial ;
- Approches de filtrage fréquentiel ou spectral.

Comme l'indique son nom, le filtrage spatial fait référence à un filtrage dans le domaine spatial. Les méthodes de filtrage opèrent ainsi directement sur l'ensemble des pixels composant l'image. Le filtrage fréquentiel fait référence à un filtrage dans un domaine de transformée de Fourier des données.

Nous discutons brièvement le principe ainsi que les méthodes fréquemment utilisées dans chacune des deux classes de filtrage.

2.3.1 Filtrage spatial

Les plus simples opérateurs pour filtrer une image sont appliqués dans le domaine spatial. Ces opérateurs utilisent une fonction du voisinage pour déterminer la valeur du pixel après filtrage. D'une manière générale, le principe de filtrage spatial peut être expliqué dans le schéma de la figure 2.2.

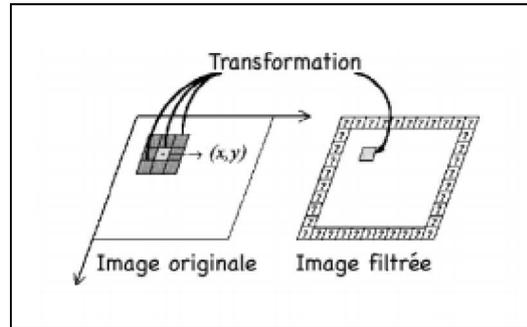


Figure 2.2: Illustration du principe du filtrage spatial en fonction du voisinage.

Les filtres opérant dans le domaine spatial sont groupés dans deux classes principales: les filtres linéaires et les filtres non linéaires.

2.3.1.1 Filtrage linéaire

Dans le cas d'un filtrage linéaire, on considère que le bruit est additif. Le filtre linéaire permet le lissage de l'image en appliquant une fonction linéaire sur les valeurs des pixels de l'image. Ce type de filtres est souvent appliqué lorsque le bruit provient des phénomènes parasites aléatoires qui suivent ou non une distribution de probabilité connue. Un point faible de ce filtrage est qu'il produit souvent un problème aux contours. Le filtre spatial linéaire le plus connu par sa simplicité est le filtre moyeneur. Ce filtre remplace la valeur initiale d'un pixel donné par la valeur moyenne de l'ensemble de ses voisins.

La figure 2.3 montre l'effet du filtre moyeneur de taille 5×5 sur un bruit additif gaussien.

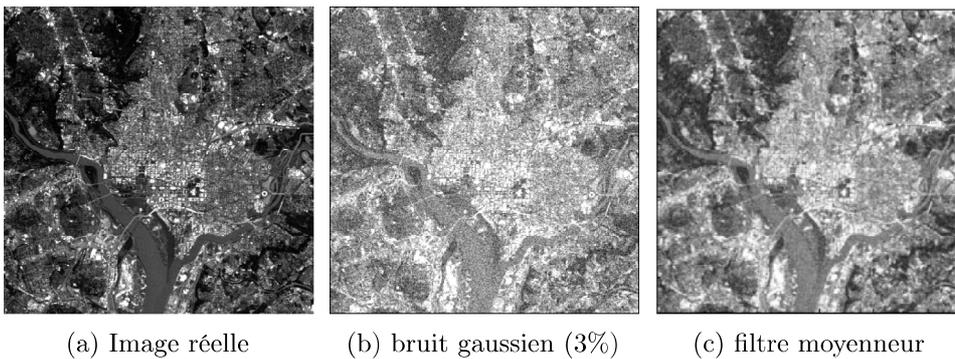
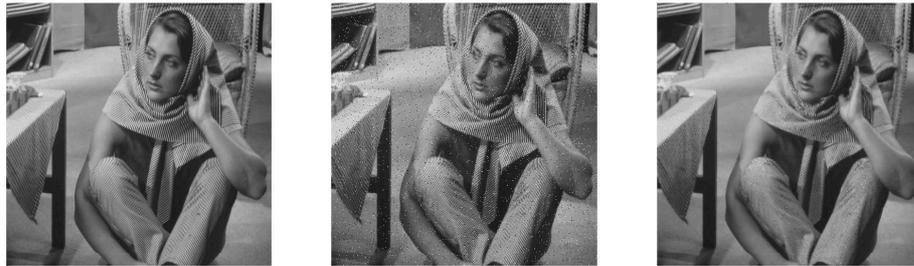


Figure 2.3: prétraitement d'une image radar bruitée (bruit gaussien) par filtre moyen

2.3.1.2 Filtrage non linéaire

Le filtre non linéaire est efficace pour les sources de bruit impulsionnel. Ces filtres reposent sur des heuristiques et le résultat de filtrage ne provient pas d'une combinaison linéaire de pixels.

Dans le cas général, les filtres non linéaires permettent de réduire le bruit dans l'image sans l'identifier explicitement. Ces filtres éliminent souvent le bruit dans une mesure raisonnable, mais les images obtenues sont par contre souvent floues et les bords invisibles. L'exemple le plus classique de filtre non linéaire est le filtre médian (aussi nommé filtre de Tuckey). La figure 2.4 montre l'effet du filtre médian sur l'image Barbara après l'ajout d'un bruit "poivre et sel".



(a) Image non bruitée (b) bruit "poivre et sel" (c) Application du filtre median

Figure 2.4: prétraitement de l'image de Barbara bruitée (bruit "poivre et sel") par filtre médian

2.3.2 Filtrage fréquentiel ou spectral

Le domaine fréquentiel ou domaine spectral est obtenu après une transformée en cosinus discrète (TCD) ou une transformée de Fourier discrète (TFD). Le filtrage dans un domaine fréquentiel est appliqué dans plusieurs opérations de traitement de l'image tels que la suppression du bruit, le lissage et le filtrage anti-repliement lié au changement de la fréquence d'échantillonnage. Le filtrage TCD est à la base de différents standards de compression de l'image et vidéo (JPEG, MPEG, H.261 et H.263).

Typiquement, les approches fréquentielles ou spectrales sont basées sur les étapes suivantes :

- Calcul de la transformée de Fourier de l'image ;
- Multiplication par une fonction de transfert ;
- Transformation inverse de Fourier du résultat.

D'une manière générale, il existe trois types de filtres (figure 2.5) :

- Le filtre passe bas : permet d'atténuer les hautes fréquences de l'image. Ainsi, il diminue le bruit en ne laissant passer que les fréquences basses mais l'image devient floue (les détails sont atténués) ;
- Le filtre passe haut : permet d'éliminer les basses fréquences et d'accroître les contours et les détails de l'image. Cependant, il amplifie le bruit dans le signal ;

- Le filtre passe bande : permet de ne conserver que les fréquences situées dans une bande donnée. Il procède ainsi par élimination de certaines fréquences indésirables présentes dans l'image.

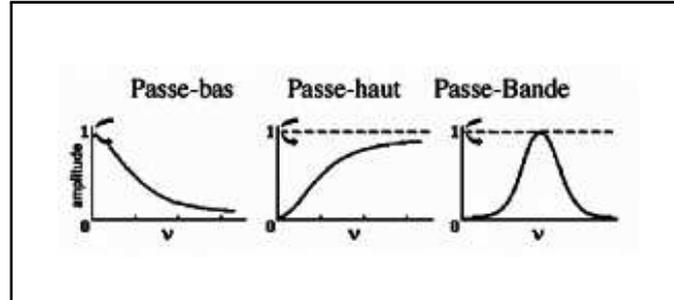


Figure 2.5: Types de filtres usuels

Communément, le choix de filtre à appliquer est fortement lié au type de prétraitement souhaité par l'utilisateur.

Considérant notre approche de prétraitement (que nous détaillons ultérieurement), nous sommes intéressés par un filtre spécifique : le filtre homomorphique.

2.3.3 Le filtre homomorphique

Le filtre homomorphique (H) est un filtre linéaire passe haut. Considérant une image donnée, ce filtre affecte différemment les hautes et les basses fréquences. Cette spécificité lui permet d'atténuer les basses fréquences (luminosité du fond de l'image) et d'amplifier les hautes fréquences (luminosité des détails)[Kla00].

L'expression de la fonction de transfert du filtre homomorphique est :

$$H(w_x, w_y) = (h - l) \cdot \left(1 - \exp\left(-\frac{w_x^2 + w_y^2}{2\delta_w^2}\right)\right) + l \quad (2.3)$$

où w_x et w_y sont les composantes fréquentielles du point des coordonnées (x, y) .

La composante " l " représente le gain en basses fréquences donc la luminosité de l'image.

La composante " h " représente le gain en hautes fréquences donc le contraste de l'image et δ_w représente la fréquence de coupure du filtre homomorphique.

La figure 2.6 montre le résultat d'application du filtre homomorphique sur l'image Lena.

Étant particulièrement intéressés au rehaussement de l'image par le filtre homomorphique, nous détaillerons dans la suite l'algorithme de filtrage homomorphique et nos différentes contributions pour le prétraitement des images. Nous considérerons le cas des images sonars pour réaliser les différentes expérimentations et évaluer notre approche de filtrage.

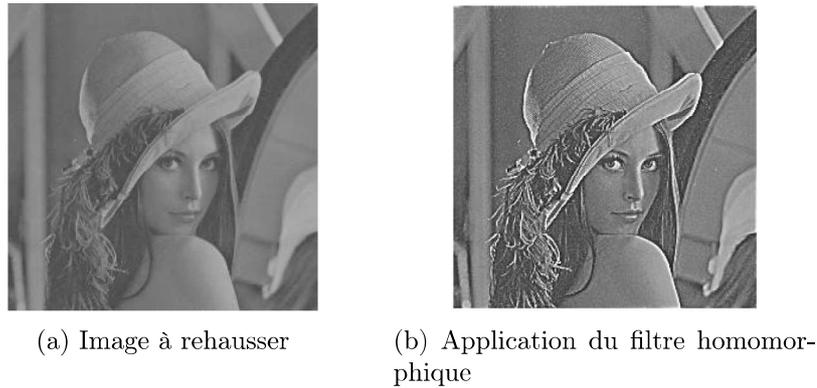


Figure 2.6: Filtre homomorphique de Lena

2.4 Exemple de prétraitement d'une image naturelle : cas d'une image sonar

Le terme SONAR (*SOund Navigation And Ranging*) désigne l'ensemble des systèmes de localisation des objets et d'imagerie du fond marin. Le principe général de fonctionnement de ces systèmes est fondé sur la réflexion des ondes sonores dans le milieu marin. Le système sonar émet des impulsions ultrasonores et reçoit les ondes réfléchies par les obstacles à l'aide d'un capteur (figure 2.7).

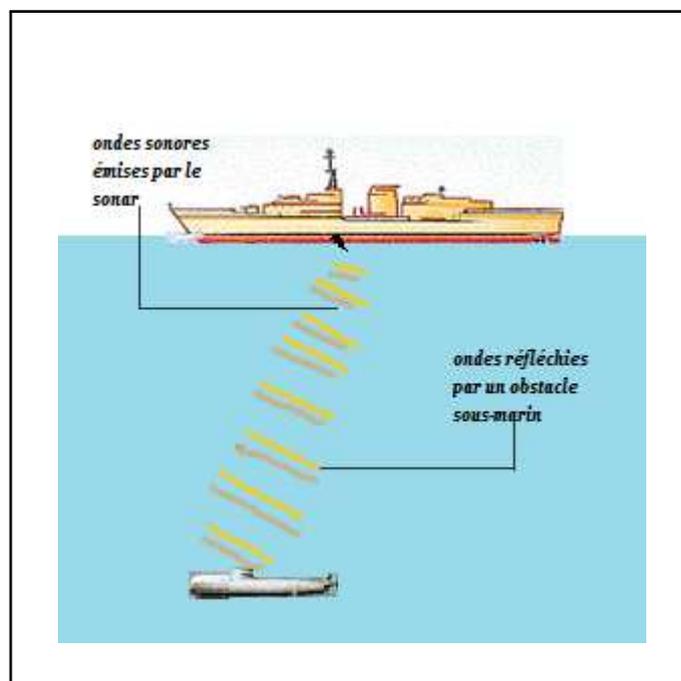


Figure 2.7: Détection d'un objet par un système sonar.

Grâce au progrès de l'électronique numérique, de nombreux systèmes sonars sont apparus. Parmi les systèmes les plus répandus, nous mentionnons la caméra acoustique, le sonar interférométrique, le Sonar à Antenne Synthétique (SAS)², le sonar paramétrique et le sonar à balayage latéral [LLFZ03]. Les images obtenues à l'aide de ces systèmes sont de grand intérêt pour des applications civils et militaires. Mentionnons comme applications l'archéologie sous-marine, la localisation de pipelines ou de déchets immergés et la détection de mines sous-marines pour la protection des ports de navigation [Lur02].

Considérant l'importance du domaine d'exploitation des mines sous-marine, plusieurs études ont été intéressées par la détection des mines dans un milieu acoustique en utilisant des systèmes à haute fréquence. Les images fournies par ces systèmes sont exploitées pour la détection et la classification des objets se trouvant sur le fond marin ou enfouis dans les sédiments, notamment les mines sous-marines [GH98, HG04, HG99, KSBD07]. Dans ce contexte, les objets détectés sont traités en exploitant les propriétés de leur ombre ou de l'intensité de réflexion de l'onde sur l'objet.

Cependant, en raison de la complexité de l'environnement océanique et des propriétés optiques particulières de la lumière dans l'eau (phénomènes d'absorption et de diffusion), l'image sonar résultante est polluée par le bruit notamment le *speckle*.

Dans le cadre de notre étude effectuée dans le domaine sonar, nous sommes particulièrement intéressés par le problème de prétraitement des images SAS.

2.4.1 Prétraitement d'une image sonar

Le sonar à antenne synthétique (SAS) est caractérisé par son excellente résolution (de quelques cm) [HG04, GH98, KSBD07]. Les images ainsi obtenues sont alors d'un grand intérêt pour la détection et la classification des objets posés sur le fond marin ou enfouis dans les sédiments. Un exemple d'une image SAS d'une zone renfermant des objets totalement et partiellement enfouis est présenté sur la figure 2.8. L'image sonar montre deux types de mines (sphérique (a) et cylindrique (b)).

²Un système acoustique issu du Radar à Ouverture Synthétique (ROS, en anglais SAR, *Synthetic Aperture Radar*) est apparu dans les années 1950 pour former des images de haute résolution. Le sonar à antenne synthétique trouve tout son intérêt dans la détection d'objets enfouis et fait encore l'objet de recherches actives.

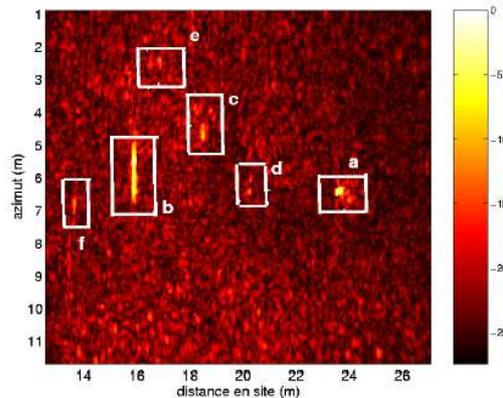


Figure 2.8: Exemple d'une image SAS présentant des objets enfouis et posés sur le sédiment marin.

L'image SAS présentée sur la figure 2.8 est issue de données enregistrées lors de la campagne BMC'99 (Buried Mine Classification) par le GESMA (Groupe d'Etudes Sous- Marines de l'Atlantique, DGA/DCE/GESMA, Brest). L'image montre une mine sphérique à droite (a) posée sur le fond marin, des mines enfouies (b, d et e), un rocher (c) et un objet non identifié (f).

En raison des propriétés du milieu sous-marin, les images sonars sont très bruitées, l'éclairage est non uniforme et les contrastes sont faibles [BQJM06]. Plusieurs travaux de recherche ont été alors développés dans le cadre de prétraitement des images sonars pour améliorer les processus en aval, notamment la détection des objets enfouis dans le sédiment sous-marin [MCH03]³.

Compte tenu des propriétés du filtre homomorphique, nous présenterons une nouvelle approche de prétraitement que nous détaillerons dans le cadre spécifique des images obtenues au moyen d'un sonar à antenne synthétique (SAS). Nous utilisons l'image SAS (figure 2.8) comme référence pour la plupart des travaux appliqués dans le domaine sonar.

2.4.2 Rehaussement homomorphique des images

Dans notre approche de prétraitement, nous sommes surtout intéressés au contraste correspondant à la différence existante entre les pixels de plus fortes intensités habituellement qualifiés de « clairs », et ceux de plus faibles intensités ainsi qualifiés de « pixels sombres ». Nous traitons les propriétés du filtre homomorphique pour améliorer les résultats de filtrage.

L'algorithme de filtrage se résume dans les six étapes suivantes :

³Une étude complète des approches récentes de traitement des images sonars est réalisée dans notre travail[MHMS12]

1. l'image est décomposée suivant la formule suivante :

$$g(x, y) = i(x, y) \cdot r(x, y) \quad (2.4)$$

avec $g(x, y)$ est l'image provenant du capteur, $i(x, y)$ le facteur multiplicatif d'illumination et $r(x, y)$ est la fonction de réflectance.

La composante d'illumination subit des variations faibles et représente donc les basses fréquences alors que la composante de réflectance subit des variations plus importantes qui sont associées aux moyennes et hautes fréquences dans la transformée de Fourier.

2. Séparation des composantes d'illumination et de réflectance en calculant le logarithme népérien (\ln) de l'image :

$$g(x, y) = \ln(f(x, y)) = \ln(i(x, y) \cdot r(x, y)) = \ln(i(x, y)) + \ln(r(x, y)) \quad (2.5)$$

3. Calcul de la transformée de Fourier de la \ln de l'image :

$$G(w_x, w_y) = I(w_x, w_y) + R(w_x, w_y) \quad (2.6)$$

4. Filtrage passe haut de la transformée de Fourier : multiplier le résultat par le filtre de transfert $H(w_x, w_y)$:

$$S(w_x, w_y) = H(w_x, w_y) \cdot I(w_x, w_y) + H(w_x, w_y) \cdot R(w_x, w_y) \quad (2.7)$$

5. Calcul de la transformée de Fourier inverse pour revenir dans le domaine spatial
6. Application de la fonction exponentielle pour récupérer l'image filtrée.

La définition de la fonction de transfert du filtre homomorphe se base sur la précision des valeurs des paramètres l et h . Dans la suite, nous examinerons les valeurs de ces paramètres pour améliorer les performances de notre méthode de filtrage.

D'autre part, les valeurs de ces paramètres doivent être choisies d'une manière critique pour amplifier les hautes fréquences et diminuer les basses fréquences. De ce fait, nous définissons la condition nécessaire et non suffisante suivante :

$$l < 1, h > 1 \text{ et } \delta_w \geq 0 \quad (2.8)$$

En conséquence, nous veillerons à choisir subjectivement les valeurs des paramètres permettant la correction des défauts de luminance.

La figure 2.9 montre un exemple de différentes visualisations de la même image de test(2.8) suite à la modification des paramètres l et h du filtre homomorphe.

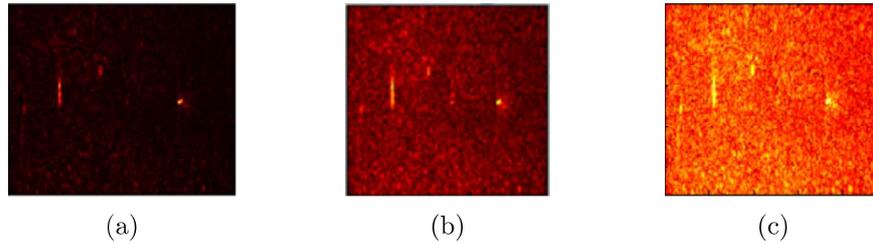


Figure 2.9: Illustration du filtre homomorphique. (a) image d'origine, (b) image rehaussée par le filtre homomorphique avec $l = 0.1$, $h = 1.5$ et $\delta_w = 0.2$ et (c) image rehaussée en fixant les valeurs des paramètres : $l = 0.9$, $h = 1.1$ et $\delta_w = 0.2$.

Les résultats d'application du filtre homomorphique avec des valeurs des paramètres distinctes, montrent que lorsque l'écart entre les paramètres l et h est faible (mais qu'ils respectent bien la condition de l'équation 2.8), deux défauts apparaissent dans l'image :

- Amplification du bruit de l'image: création des textures indésirables dans l'image ;
- Déformation des transitions de contraste.

Suite à l'analyse graphique des résultats, nous considérons que le cas (c) de la figure 2.9 est un cas extrême et le cas (b) de paramétrage est un cas témoin. Néanmoins, des critères de calcul de performance de filtre exploité doivent être définis pour certifier les résultats obtenus.

2.5 Définition de critères d'évaluation de la méthode de filtrage

Dans la littérature, la précision des critères d'évaluation de la méthode de filtrage est rarement réalisée. En effet, l'évaluation des performances de filtrage est souvent effectuée en montrant l'apport de l'étape de débruitage sur les étapes postérieures de la procédure de traitement de l'image.

Dans ce stade de travail, notre contribution consiste à définir des mesures nous permettant à la fois d'évaluer les performances de notre algorithme de débruitage et d'automatiser le choix des paramètres l et h pour une base d'images captées dans les mêmes conditions d'éclairage.

Considérant qu'une image contient une partie "fond" et une partie "objets", nous évaluons les performances de notre filtre dans chacune de ces deux classes. L'extraction de la partie d'intérêt (classe fond ou classe objet) est réalisée en utilisant une image vérité terrain.

Notre définition des paramètres d'évaluation est dépendante de la définition de contraste et de la luminance dans une image numérique. Ainsi, nous définissons deux critères d'évaluation que nous jugeons performants pour évaluer l'amélioration apportée aux images suite au filtrage homomorphique.

Le premier critère est le lissage du fond de l'image. Ainsi, pour contrôler les dégradations dans l'image sonar et limiter l'effet du speckle, nous mesurons le rapport de la variance, dans la classe fond, avant et après l'application du filtre homomorphique.

Nous notons ce rapport v que nous calculons par l'équation suivante :

$$v = \frac{(\sum_{p=1}^n (n_p \cdot x_i^2)) - \overline{X_i}^2}{(\sum_{p=1}^n (n_p \cdot x_f^2)) - \overline{X_f}^2} \quad (2.9)$$

où

- les x_i sont les pixels de l'image initiale et les x_f présentent les pixels de l'image filtrée dans la classe fond ;
- n_p est le cardinal des pixels de niveau de gris p dans l'image traitée (initiale ou filtrée) ;
- $\overline{X_i}$ et $\overline{X_f}$ réfèrent à la moyenne de tous les pixels de la zone fond respectivement dans l'image initiale et l'image filtrée.

Dans la suite, nous avons intérêt à évaluer la conservation des éléments pouvant servir à la localisation et la classification des objets recherchés. Considérant que la classe fond n'a quasiment plus d'importance pour la suite de notre travail, nous considérons uniquement la classe "objet" pour évaluer la préservation des détails de l'image. La définition de ce deuxième critère se fonde sur la mesure de la distance entre les deux images (initiale et filtrée).

Cette mesure (d) est calculée par l'expression suivante:

$$d = \frac{\sqrt{\sum_{p=1}^{N_e} (x_{f_p} - x_{i_p})^2}}{N_e} \quad (2.10)$$

avec x_{i_p} et x_{f_p} les pixels de niveau de gris p de la classe objets respectivement dans l'image initiale et l'image filtrée et N_e la taille de la zone objet.

Pour évaluer les performances de la méthode de prétraitement dans le domaine sonar, nous avons utilisé une deuxième image SAS que nous appelons désormais "Image2".

Une illustration de cette image ainsi que la vérité terrain est présentée dans la figure 2.10.

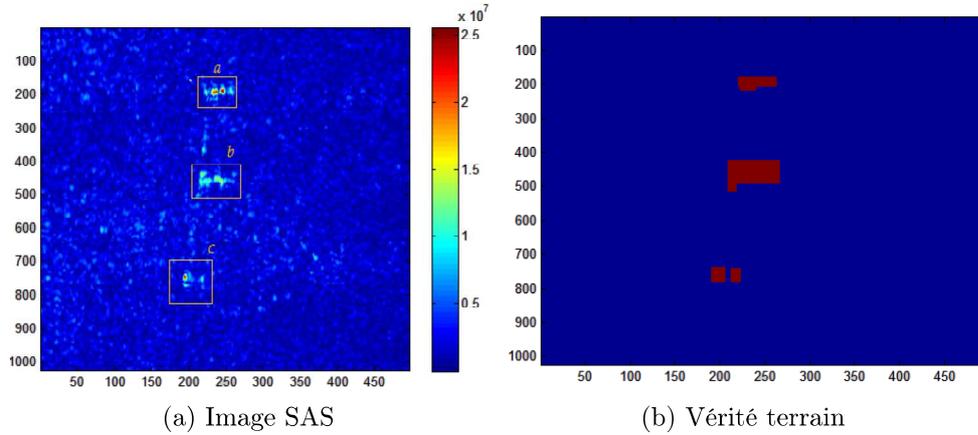


Figure 2.10: Image2 de test contenant des objets enfouis (b) et posés ((a) et (c)) sur le sédiment marin (GESMA).

Le calcul de deux quantités v et d pour un échantillon formé par les deux images SAS (image de test et Image2) est présenté dans le tableau 2.1.

	Variance v	Distance d
Image de test	3,87	0,176
Image2	85	0,40

Tableau 2.1: Évaluation de la méthode de filtrage pour un échantillon de deux images sonars

Les résultats expérimentaux révèlent une préservation des échos (objets ou encore les points brillants dans l'image sonar) pour le cas de image 1 (faible valeur de d) et un bon lissage du fond pour le cas de l'image 2 (v moyennement importante).

Dans notre étude expérimentale, l'application du filtre homomorphe dans le cas de l'image SAS de test permet une variation intense dans la profondeur de l'image. Ainsi, il s'avère nécessaire d'appliquer une méthode de changement d'échelle avant l'évaluation des performances du filtre.

Pour la suite de ce travail, nous proposons d'utiliser la méthode de changement d'échelle définie dans la formule suivante:

$$MH(i, j) = \frac{(MH(i, j) - \min(X_F)) \cdot \max(X_I)}{\max(X_F) - \min(X_I)} \quad (2.11)$$

où

- $MH(i, j)$ la valeur de niveau de gris du pixel dans l'image filtrée ;
- $\max(X_I)$ la valeur de pixel de niveau de gris maximal dans l'image initiale ;
- $\max(X_F)$ (respectivement $\min(X_F)$) est la valeur de pixel à niveau de gris maximal (respectivement minimal) dans l'image après application du filtre homomorphe.

Dans la suite, nous procédons à calculer les performances de la méthode de prétraitement pour différents cas de l et de h . Les résultats d'évaluation pour trois exemples d'application de filtre, pris au hasard, sont résumés dans le tableau 2.2.

	l	h	v	d
cas1	0,1	1,5	3,87	0,176
cas2	0,1	2	1,004	$5,5 \cdot 10^{-4}$
cas3	0,9	1,1	85	0,84

Tableau 2.2: Évaluation de la méthode de filtrage pour différentes valeurs de l et h .

Pour une comparaison visuelle des résultats obtenus, nous présentons également l'image initiale de test et les résultats d'application du filtre homomorphique sur cette image en considérant les cas 1, 2 et 3 (figure 2.11).

Le cas 1 présente le même cadre d'application du filtre homomorphique sur l'image SAS de test précédemment comparée à l'image 2(voir tableau 2.1).

L'application du filtre homomorphique, en considérant les paramètres l et h du cas 2, donne une valeur de v pratiquement égale à 1 et une distance d très faible. Ainsi, on peut conclure l'absence de l'effet du filtrage sur l'image initiale pour le cas2 malgré l'application du filtre homomorphique.

Le troisième cas présente des valeurs de h et l très proches de leurs bornes limites précisées dans l'équation 2.8. Le calcul de performances de filtrage homomorphique dans ce cas donne une valeur de v très grande et une distance d aussi relativement importante. Ceci se traduit par une variation intense dans la caractéristique contraste de l'image filtrée. On peut conclure donc que, lorsque le gain en haute fréquence se rapproche de celui en basse fréquence, l'effet de filtrage s'intensifie. L'écart entre l'image initiale et l'image filtrée est dû à une dégradation dans la qualité de l'image.

Ainsi, certaines valeurs des paramètres h et l peuvent altérer l'image initiale en y introduisant un bruit supplémentaire (cas3). D'autres valeurs peuvent avoir un effet neutre sur l'image et ne contribuent donc pas à son débruitage (cas1). Cela prouve encore une fois l'importance du choix des mesures h et l du filtre homomorphique. D'un autre côté, en comparant les résultats des trois cas considérés, le cas 1 peut être retenu comme un exemple commode pour le choix des plages des valeurs de fréquences de coupure du filtre homomorphique pour l'images sonar.

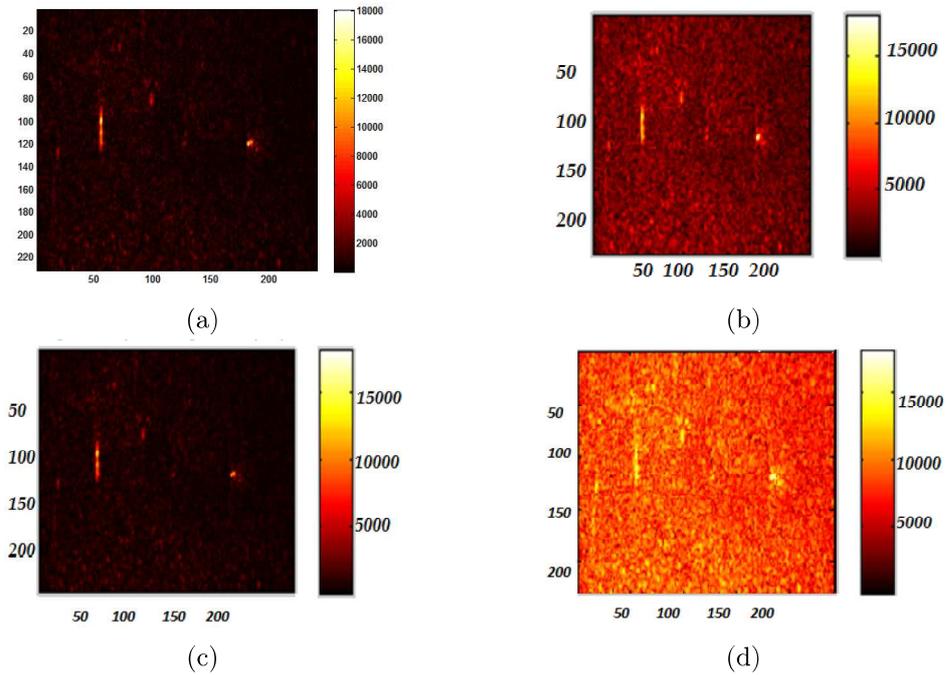


Figure 2.11: Comparaison entre l'image de test et l'image filtrée pour différentes valeurs de l et h . La figure (a) présente l'image initiale, les figures (b), (c) et (d) présentent le résultat de l'application de filtre homomorphique respectivement dans les cas 1, 2 et 3.

Si on applique le filtre Homomorphique une deuxième fois sur l'image initiale avec les mêmes paramètres précisés dans le cas 1 (considéré comme cas témoin), on obtient les résultats présentés dans la figure 2.12.

Les performances obtenus dans ce cas sont calculées par comparaison avec l'image initiale et sont de valeurs : $v = 11.77$ et $d = 0.4029$.

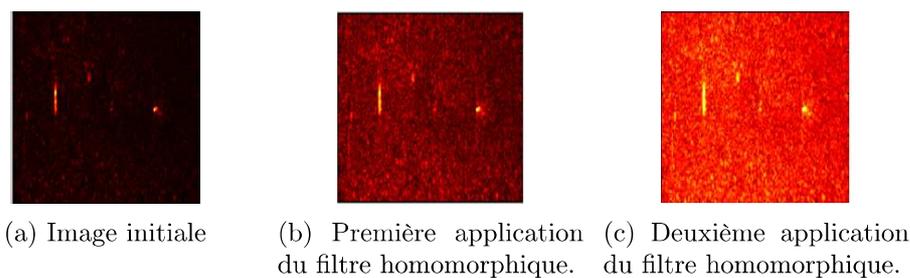


Figure 2.12: Résultats d'application successive du filtre homomorphique sur l'image SAS de test en considérant le cas1.

Les mesures de v et d , obtenues suite à deux applications successives du même filtre homomorphique, sont similaires à ceux de l'étude effectuée dans le cas 3 et donc non performantes.

Ainsi, pour toute la suite de ce travail, nous considérons les paramètres optimaux de prétraitement d'une image naturelle ceux qui optimisent leurs valeurs numériques

de d et v .

Arrivés à ce stade, nous cherchons à étudier les propriétés statistiques de l'image après application de l'approche de filtrage. L'étude théorique de l'image nous permettrait d'exploiter les propriétés des modèles statistiques pour une future exploitation dans le processus de traitement des images.

Dans le paragraphe suivant, nous comparons la modélisation statistique du résultat du filtrage avec la distribution empirique de l'image sonar (2.8).

2.6 Modélisation statistique et estimation des paramètres

Le but de ce travail est de présenter différentes illustrations graphiques permettant de justifier que l'image filtrée provient bien d'une loi donnée. Pour comparer la distribution observée avec une loi théorique, nous utilisons l'histogramme de l'image. Nous proposons alors de comparer la distribution empirique de l'image filtrée avec différents modèles statistiques.

Dans la littérature, la comparaison avec la loi normale (loi gaussienne) revêt une importance supplémentaire. D'autre part, en se basant sur les propriétés du bruit, de nombreux autres modèles statistiques ont été proposés tels que la loi de Rayleigh et la loi de Weibull. Nous choisissons alors d'utiliser la loi normale, la loi de Rayleigh et la loi de Weibull pour la modélisation statistique de l'image sonar de test.

2.6.1 Modélisation par la loi normale

La comparaison entre l'histogramme de l'image de test (2.8) (après l'application du filtre H) et la fonction densité de la loi gaussienne est présentée dans la figure 2.13. Cette comparaison est réalisée avec des différentes valeurs des paramètres du filtre homomorphique. Le pas de l'histogramme est déterminé de manière à avoir la convergence de la loi empirique en moyenne quadratique.

Nous calculons l'amplitude de chaque intervalle de l'histogramme par la quantité :

$$pas = \frac{\max(I)}{\sqrt{(N)}} \quad (2.12)$$

où $\max(I)$ présente la valeur maximale en niveau de gris de l'image initiale et N la taille de l'échantillon.

Les résultats d'une comparaison visuelle montrent que plus la distance entre les valeurs des paramètres h et l est grande plus on se rapproche de la distribution gaussienne. En outre, la moindre modification de la valeur de h du filtre homomorphique (gain en haute fréquence) influe d'une façon importante sur la courbe de la distribution gaussienne (cas (c) et (d)).

Dans la figure 2.14 nous présentons le résultat de modélisation gaussienne de l'image de test considérée avant et après l'application du filtre H .

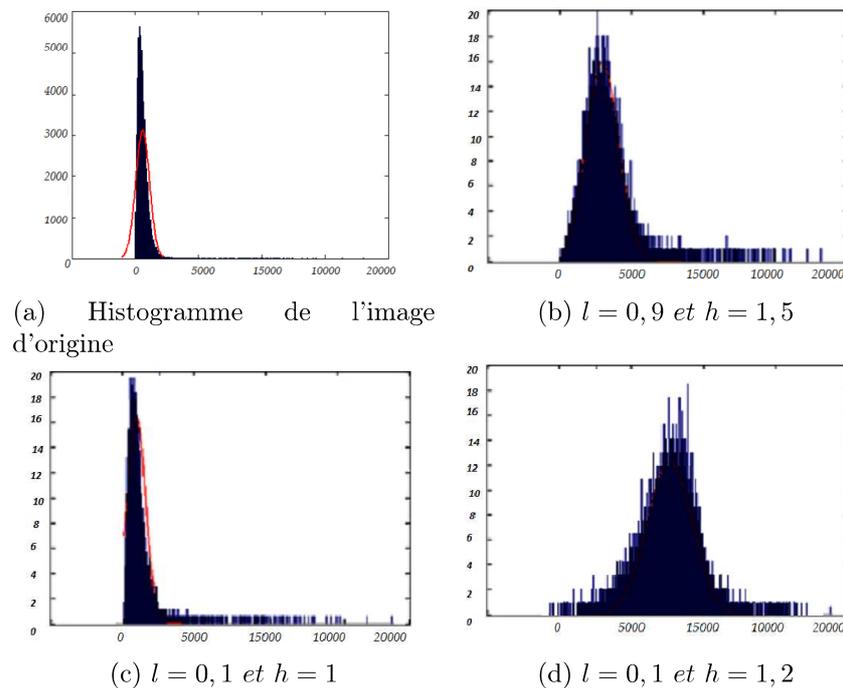


Figure 2.13: Modélisation de l'image sonar par la loi gaussienne et illustration des résultats pour différentes valeurs des paramètres h et l .

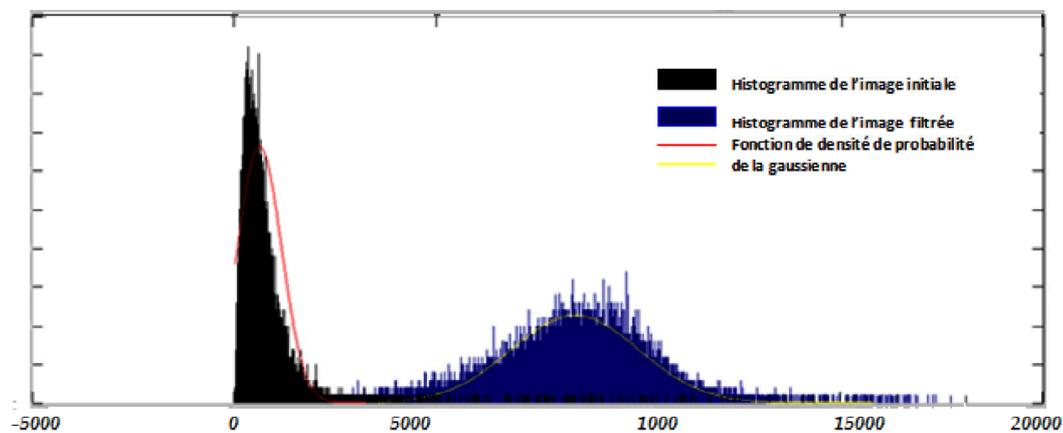


Figure 2.14: Modélisation par la loi gaussienne pour l'image initiale et filtrée (cas1).

Une comparaison visuelle montre que le résultat obtenu est intéressant dans le cadre de dévoiler une meilleure modélisation de l'image sonar à la distribution gaussienne après son filtrage par le filtre homomorphique.

Dans la suite, nous proposons d'appliquer d'autres modèles statistiques. Nous étudions alors le modèle de Rayleigh et le modèle de Weibull bien appliqués dans la littérature pour la modélisation des images sonars [AL04].

2.6.2 Modélisation par la loi de Rayleigh

La distribution de Rayleigh est définie en fonction de son paramètre caractéristique « α » [Sun08].

La fonction densité de la loi de Rayleigh est :

$$P(A) = \frac{A}{\alpha^2} \cdot \exp\left(\frac{-A^2}{2 \cdot \alpha^2}\right) \quad (2.13)$$

α correspond à la position du maximum de la densité de probabilité.

Afin de comparer le résultat de deux modélisations (loi normale et loi de Rayleigh), nous illustrons dans la figure 2.15 l'allure de l'histogramme et la modélisation par la loi normale et par la loi de Rayleigh de l'image filtrée.

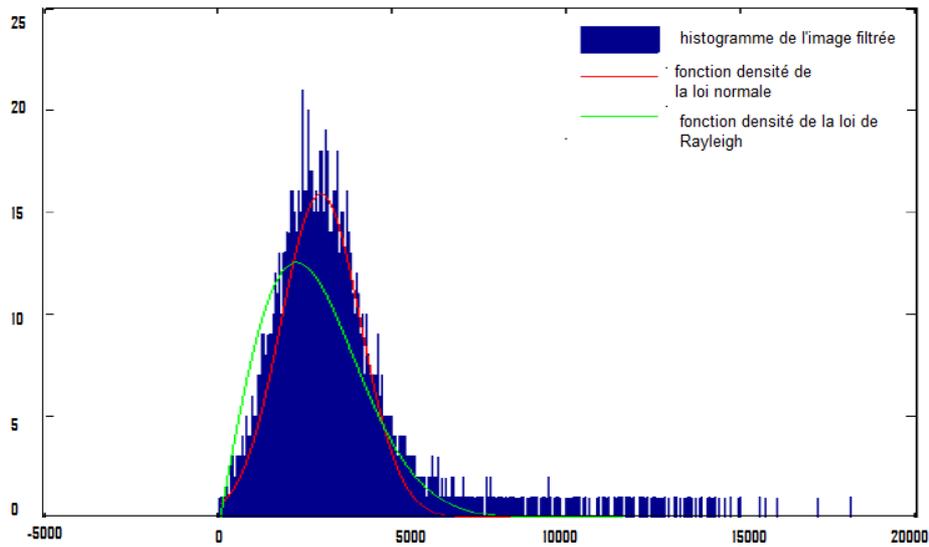


Figure 2.15: Modélisation par la loi gaussienne et la loi de Rayleigh de l'image filtrée ($l = 0, 1$, $h = 1, 5$ et $\delta_w = 0, 2$) et comparaison avec la loi empirique de l'image

Le résultat visuel de cette comparaison montre qu'après son filtrage par le filtre homomorphique, l'image est mieux modélisée par la loi normale que par la loi de Rayleigh.

2.6.3 Modélisation par la loi de Weibull

Nous examinons également l'adéquation du résultat de filtrage avec une la distribution de Weibull (loi non gaussienne)[Sun08].

La fonction densité de la loi de Weibull est définie en fonction de deux paramètres (δ et β) comme suit :

$$W(A) = \frac{\delta}{\beta} \cdot (A/\beta)^{\delta-1} \cdot \exp\left(-\frac{A}{\beta}\right)^\delta \quad (2.14)$$

La modélisation des différentes lois utilisées exige une estimation des paramètres. Le tableau 2.3 présente les valeurs des paramètres estimés pour chacune des trois

distributions dans le cas de l'image de test et après application du filtrage homomorphique (cas $l = 0, 1$, $h = 1, 5$ et $\delta_w = 0, 2$).

Distribution	Image initiale	Image filtrée
Loi normale	$\mu = 603,76$ $\sigma = 545,19$	$\mu = 2884,7$ $\sigma = 1137$
Loi de Rayleigh	$\alpha = 575,22$	$\alpha = 2196,6$
Loi de Weibull	$\beta = 665,62$ $\sigma = 545,19$	$\beta = 3251,5$ $\sigma = 104,04$

Tableau 2.3: Calcul des paramètres estimés des trois modèles statistiques pour l'image initiale et l'image filtrée

2.7 Évaluation des performances des modèles statistiques

Afin de montrer si la distribution de l'image filtrée suit une distribution spécifique (loi gaussienne, loi de Rayleigh ou loi de Weibull), nous avons recours au test du chi-deux (κ^2) et celui de Kolmogorov Smirnov [Bru87].

Le calcul de la distance κ^2 est défini comme suit :

$$\kappa^2 = \frac{\sum_{i=1}^{N_{val}} (k_i - N \cdot p_i)^2}{N \cdot p_i} \quad (2.15)$$

avec k_i le nombre de réalisations de niveau de gris i , p_i la probabilité estimée de i et N_{val} le nombre de valeurs en niveau de gris.

La distance de Kolmogorov est définie par :

$$d_k = \max(|(k_i - N \cdot P_i)|, i = 1..N_{val}) \quad (2.16)$$

avec k_i est la somme des réalisations de toutes les valeurs de niveau de gris inférieur à i et P_i est la valeur en i de la fonction de répartition associée à p_i .

De ce fait, plus la valeur de ces deux critères est importante, moins la modélisation statistique des données est bonne.

Les résultats du calcul des performances des différents modèles statistiques sur les deux images sonars (image de test et image2) avant et après l'application du filtre homomorphique sont présentés dans le tableau 2.4.

Le résultat de calcul des performances des différents modèles statistiques pour les deux images SAS montre la performance de la modélisation gaussienne après application du filtre homomorphique. Ce résultat peut être utilisé dans la suite de notre processus de recherche des objets rares, si on souhaite exploiter les propriétés de la loi normale. Nous pouvons aussi remarquer que la loi de Weibull permet une modélisation meilleure que celle obtenue par la loi de Rayleigh.

	Loi Normale		Loi de Rayleigh	Loi de Weibull
Image de test	χ_2	0,559	0,67	0,655
	$dk(10^{-4})$	3,575	4,512	1,395
Image filtrée	χ_2	0,6424	0,6674	0,6466
	$dk(10^{-4})$	1,16	3,903	1,308
Image2	χ_2	0,89	1,8505	0,7187
	$dk(10^{-4})$	2,9433	4,8995	0,65045
Image filtrée	χ_2	0,4274	0,4459	0,4303
	$dk(10^{-4})$	0,47525	2,0986	0,65041

Tableau 2.4: Comparaison des distributions de chacun des modèles statistiques pour un échantillon de deux images sonars ($l = 0, 1$ $h = 1, 5$ et $\delta_w = 0, 2$)

2.8 Tests d’hypothèse et analyse des résultats obtenus

Dans ce mémoire nous réalisons différents tests d’hypothèses [Rac11] sur une base des images SAS prétraitées selon notre approche proposée.

Plusieurs types de tests d’hypothèses sont implémentés : test de Kolmogorov-Smirnov, Shapiro-Wilk, test de Cramer et test du χ^2 . Nous détaillons chacun de ces tests ainsi que l’ensemble des résultats obtenus dans l’annexe A.

Pour chaque test d’hypothèse, nous admettons que l’hypothèse nulle consiste à l’affirmation que notre échantillon de test suit une distribution donnée. Nous calculons aussi la probabilité de rejet à tort l’hypothèse nulle pour un risque $\alpha = 5\%$. Nous appelons cette probabilité *p-valeur*. Les résultats de cette étude nous amènent à comparer pour chaque test la distribution empirique de notre image à la fonction de répartition estimée.

Un échantillon des résultats obtenus avec le test de Cramer réalisé sur cet échantillon d’images après application de l’approche de filtrage est présenté dans le tableau 2.5.

	Image initiale	Image filtrée
P-valeur	$8,2808 \cdot 10^{-6}$	$17,4522 \cdot 10^{-4}$

Tableau 2.5: Résultats du calcul de p-valeur pour le test de Cramer appliqué sur l’image SAS

Le test de Cramer admet comme hypothèse nulle que l’échantillon de départ suit la loi normale avec une moyenne nulle et un écart type $\delta = 1$. La distance de Cramer ainsi trouvée (augmentation de la valeur de *p-value* après filtrage) indique l’adéquation de l’image filtrée à la distribution statistique normale pour le même risque.

Afin de mettre l’accent sur l’apport de la méthode de filtrage, nous réalisons une comparaison entre la fonction de répartition empirique de l’image initiale et l’image filtrée. Un exemple de cette comparaison est présenté dans les figures: 2.16 et 2.17.

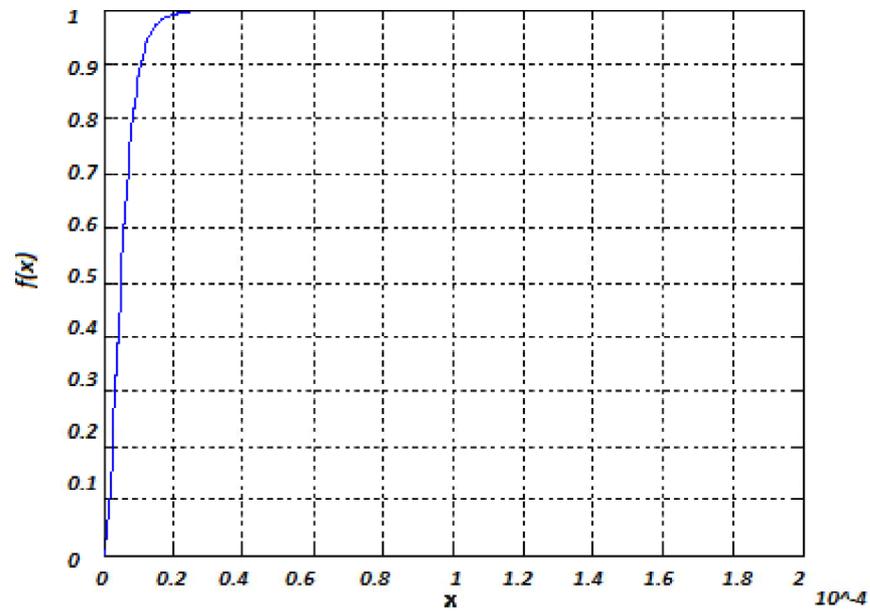


Figure 2.16: Allure de la fonction de répartition empirique de l'image initiale.

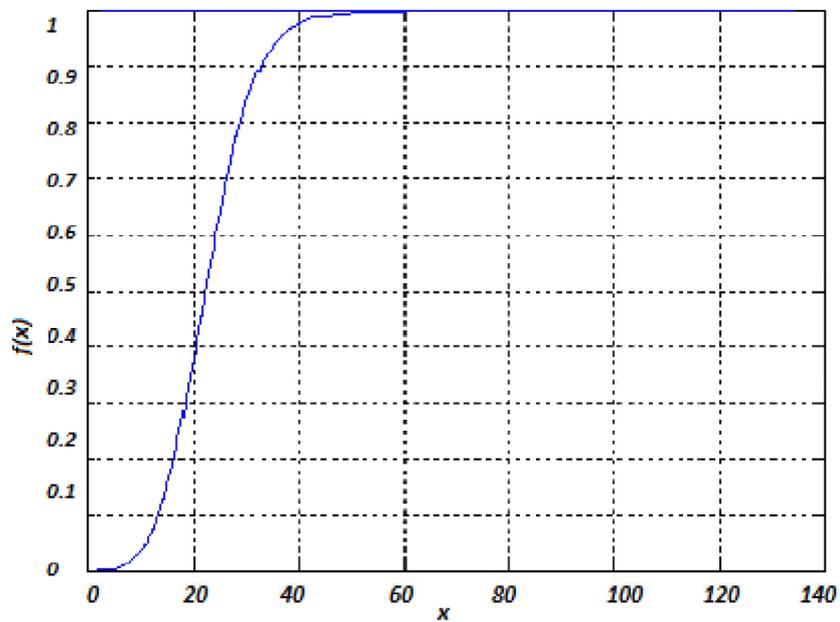


Figure 2.17: Allure de la fonction de répartition empirique de l'image sonar après application de la méthode de filtrage.

L'amélioration de p -valeur (après l'application de la méthode de filtrage) pour les tests admettant l'hypothèse de normalité et l'allure de la fonction de répartition adjacente à la loi normale, nous conduit à étudier la normalité de l'image filtrée.

2.9 Tests de normalité : méthodes empiriques et graphiques

Dans cette partie, nous nous intéressons aussi aux tests de compatibilité mais nous visons uniquement la loi normale. Il s'agit ici d'utiliser les indicateurs usuels (par exemple l'indicateur de normalité I_n) et graphique (droite de Henry) [R.J62, BW07] pour vérifier l'adéquation à la loi normale sans déterminer la distribution théorique la plus compatible à l'image filtrée.

2.9.1 Indicateur de normalité

Une caractéristique importante de la loi normale est la valeur du rapport entre l'écart absolu moyen (en anglais *Mean Absolute Déviation* MAD) et l'écart-type [Par08]. Cette valeur est calculée selon la formule suivante:

$$I_n = \sqrt{\frac{2}{\pi}} \simeq 0,7979 \quad (2.17)$$

Le calcul de cet indicateur permet alors d'examiner l'écart de notre image de test à la loi normale. Une étude comparative entre la valeur de cet indicateur pour le cas de l'image sonar avant et après le filtrage homomorphique permet de prouver que suite à l'application du filtre H , l'indice de normalité se rapproche de sa valeur initiale I . Ce résultat est démontré dans le tableau 2.6.

	Image initiale	Image filtrée
Valeur de I_n	0,5741	0,7442
Distance à la normale	0,2238	0,0537

Tableau 2.6: Comparaison de la valeur de l'indicateur usuel de normalité I pour le cas de l'image SAS avant et après application de la méthode de filtrage.

Il paraît ainsi difficile de rejeter d'emblée l'adéquation de notre image filtrée à la loi normale. Ce résultat est dans la suite confirmé par le test des opérateurs graphiques de normalité.

2.9.2 Le Q-Q plot et la droite de Henry

Le « quantile-quantile plot » (Q-Q plot) est une technique graphique permettant, dans le cas général, de comparer les distributions de deux ensembles de données [BW07]. Pour étudier la normalité de notre échantillon, nous appliquons cette méthode dans le cas particulier où nous admettons qu'un des ensembles des données est généré à partir de la loi normale.

Notre algorithme implémenté peut être résumé dans les étapes suivantes :

1. Trier les données de l'image de test de manière croissante pour former une série $(x(i))$;

2. Calculer la fonction de répartition empirique F_i pour chaque valeur $x(i)$.
La fonction de répartition estimée F_i est calculée dans notre implémentation en appliquant la formule suivante :

$$F_i = \frac{i - 0,375}{n + 0,25} \quad (2.18)$$

3. Calculer les quantiles successifs z_i d'ordre F_i en utilisant l'inverse de la loi normale centrée et réduite.
4. Dénormalisation des données initiales en appliquant la transformation suivante:

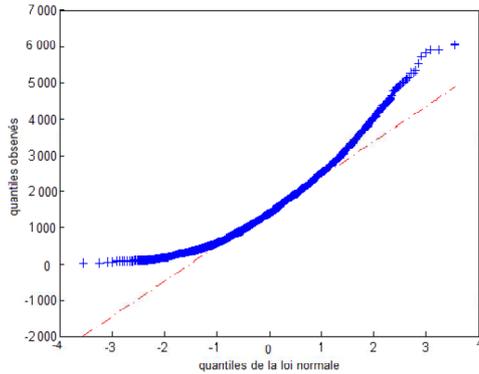
$$x_d(i) = z(i) \cdot \delta + \mu \quad (2.19)$$

avec δ est la valeur de l'écart type de l'image initiale et μ est la moyenne de tous les pixels de l'image initiale.

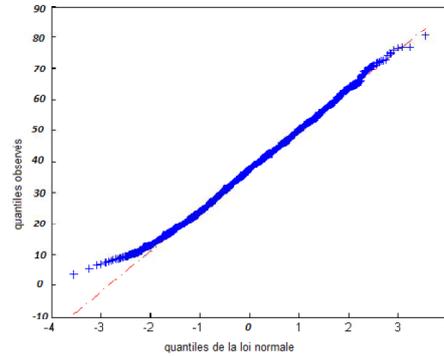
Si les données sont compatibles avec la loi normale, les points $(x(i), x_d(i))$ forment une droite, qu'on appelle droite de Henry, et sont alignés sur la diagonale principale. Suite à l'application de cet algorithme, nous traçons la droite de Henry que nous analysons attentivement.

Un exemple de traçage de la droite de Henry pour le cas deux échantillons formés respectivement par un bruit de la loi de Weibull et un bruit de la loi de Rayleigh est représenté sur la figure 2.18. L'allure de la courbe de Henry est calculée pour chacun de deux échantillons filtrés avec les paramètres optimaux de la méthode de filtrage.

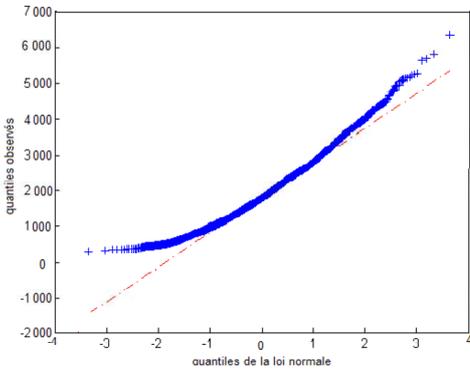
Les allures des courbes de Henry obtenues pour les différentes distributions examinées, présentent des valeurs plus alignées sur la diagonale principale dans le cas des images filtrées affirmant ainsi la normalité de ces dernières. Ce résultat permet de confirmer la conclusion précédente admettant l'adéquation de la distribution de l'image à la loi normale après application du filtre homomorphique.



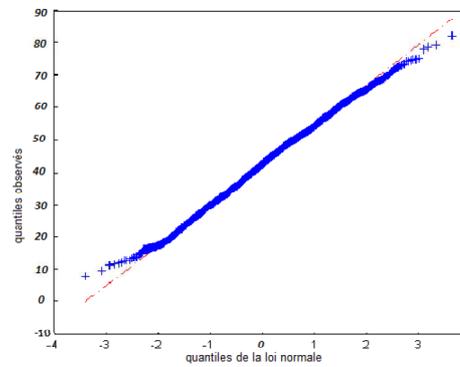
(a) Échantillon initial (distribution de Weibull)



(b) Image filtrée



(c) Échantillon initial (distribution de Rayleigh)



(d) Image filtrée

Figure 2.18: Illustration de Q-Q plot de deux échantillons avant et après application de l'approche de filtrage (l'échantillon est coloré en bleu et la normale est présentée par la droite rouge).

2.10 Conclusions

Considérant la nature bruitée de l'image naturelle, précisément la non-uniformité de l'éclairage et le faible contraste, notre but dans ce chapitre est la correction de ces distorsions en utilisant un type de filtre spécifique : le filtre homomorphique. Ainsi, après avoir énuméré les sources, les types et les méthodes de filtrage, nous sommes intéressés aux propriétés du filtre homomorphique. Nous avons étudié au début les paramètres de ce filtre et l'effet de la variation de leurs valeurs. Ensuite nous avons introduit des critères d'évaluation du filtrage nous permettant de juger les performances de l'approche proposée. La définition que nous avons proposée nous a permis de fixer les valeurs des paramètres de filtre. Procédant ainsi, nous avons contribué à automatiser l'application de filtre H sur des images prises dans les mêmes conditions de capture.

Afin d'évaluer qualitativement les performances de filtrage et en vue de comparer le résultat obtenu avec les différentes distributions théoriques existantes, une étude

statistique de l'image filtrée est réalisée. Les différents tests appliqués permettent de confirmer l'hypothèse que l'image filtrée a une meilleure modélisation gaussienne suite à son prétraitement. Ce résultat est considéré intéressant pour la suite du processus de détection étant donné que beaucoup des algorithmes existants sont basés sur la gaussianité des données traitées.

Tout au long de la partie expérimentale de ce chapitre, nous avons adopté le cas de l'image sonar comme exemple d'application de notre approche. Cet exemple nous a permis d'étudier de près les propriétés de l'image sonar. Nous les considérons intéressantes pour notre travail sur la détection des objets rares.

Segmentation des images : pré-détection des objets rares

Sommaire

3.1	Introduction	57
3.2	Segmentation des images	57
3.2.1	Approches région	57
3.2.2	Approches contour	58
3.2.3	Méthodes sur histogramme	59
3.3	Techniques de binarisation et choix du seuil	60
3.3.1	Seuillage global	60
3.3.2	Seuillage local	60
3.3.3	Seuillage hybride	60
3.4	Seuillage d'une image unimodale	61
3.4.1	Différentes approches existantes	62
3.4.2	Seuillage global automatique	64
3.5	Étude théorique de l'approche de segmentation	67
3.5.1	Seuillage entropique	67
3.5.2	Entropie et hypothèses de calcul	68
3.5.3	Variation de l'entropie en fonction du seuil de segmentation	70
3.5.4	Fonction Sigmoidale	71
3.6	Seuillage entropique et pré-détection des objets d'intérêt	71
3.6.1	Estimation de la courbe d'entropie	71
3.6.2	Étude des variations de la fonction d'estimation et seuillage de l'image sonar.	73
3.6.3	Algorithme de pré détection des objets d'intérêts	76
3.7	Variations de λ en fonction du pourcentage d'occupation en objets de l'image	77
3.8	Tests et évaluation des performances	82
3.9	Conclusions	84

3.1 Introduction

Afin de pouvoir détecter les objets rares, il est nécessaire de fragmenter l'image initiale en une ou plusieurs zones d'intérêt où les objets sont susceptibles de se trouver. Cette étape de segmentation permet de réduire les zones d'intérêt dans l'image et de limiter par la suite le temps de calcul puisque seules les zones d'intérêt seront traitées.

Dans le présent chapitre, nous proposons une nouvelle approche d'extraction des objets d'intérêt qui réduit les zones d'intérêt dans l'image et permet de guider le processus de détection. Dans la première partie de ce chapitre, nous présentons brièvement les différentes approches de segmentation et de seuillage d'un histogramme unimodal. Dans la deuxième partie de ce chapitre, nous détaillons les différentes étapes de notre algorithme de seuillage. Les résultats opérationnels obtenus pour la pré-détection des objets d'intérêt dans une image naturelle sont détaillés à la fin de ce chapitre.

3.2 Segmentation des images

La segmentation est une étape primordiale pour la détection des objets dans une image. Le but de la segmentation est de rassembler les pixels de l'image de telle sorte que les pixels appartenant à une classe soient plus similaires entre eux que ceux des autres classes. La segmentation permet ainsi une analyse bas-niveau des données.

Dans la littérature, il existe plusieurs approches de segmentation ; chacune possède ses avantages et ses inconvénients. Le choix de la méthode de segmentation dépend de plusieurs facteurs dont on peut citer : la nature de l'image (éclairage , présence de bruit, contours flous, . . .), les opérations à effectuer dans les étapes ultérieures du processus de détection et les caractéristiques du système d'exploitation (complexité, taille de mémoire libre, . . .). En conséquence, il n'existe pas d'approche universelle pour segmenter une image.

D'une manière générale, les principales approches de segmentation d'image peuvent être divisées en deux types : approches région et approches contour.

3.2.1 Approches région

L'approche de segmentation en régions consiste à regrouper les pixels de l'image en régions connexes. La segmentation est basée sur la recherche des points de l'image possédant des propriétés similaires comme le niveau de gris, la texture, l'orientation, . . .

Une segmentation par région est donc une partition d'une image I en une ou plusieurs régions R_1, R_2, \dots, R_n vérifiant un critère d'homogénéité tel que :

$$\bigcup_i^n R_i = I, \quad i \in [1, n] \text{ et } R_i \cap R_j = \emptyset \quad (3.1)$$

Souvent, les méthodes de segmentation en régions sont basées sur les valeurs de niveaux de gris de l'image. Une méthode classique de segmentation par région

consiste à binariser l'image par seuillage en utilisant l'information globale de l'image comme l'histogramme ou les grandeurs statistiques des pixels.

3.2.2 Approches contour

Contrairement aux approches régions qui cherchent les similarités, les approches contour cherchent plutôt les dissimilarités. Le principe de ces approches se base sur la recherche des points de discontinuité entre deux zones de caractéristiques différentes. Les points situés à l'intérieur d'un contour fermé sont ensuite regroupés pour former une région homogène [CHE00]. Les points de discontinuité dans l'image sont généralement extraits par filtrage en utilisant l'une des deux approches suivantes:

- Approche gradient : calcul des extrema locaux dans la direction du gradient ;
- Approche laplacien : calcul de laplacien puis détermination des passages par zéro de celui-ci.

Il existe plusieurs algorithmes de segmentation par contour. Les opérateurs de Roberts, Sobel et Canny sont des exemples d'approches gradient bien répandues utilisées pour la détection des contours.

Les méthodes de segmentation par contour retournent les frontières entre les régions alors que les approches région retournent directement les régions (voir figure 3.1).

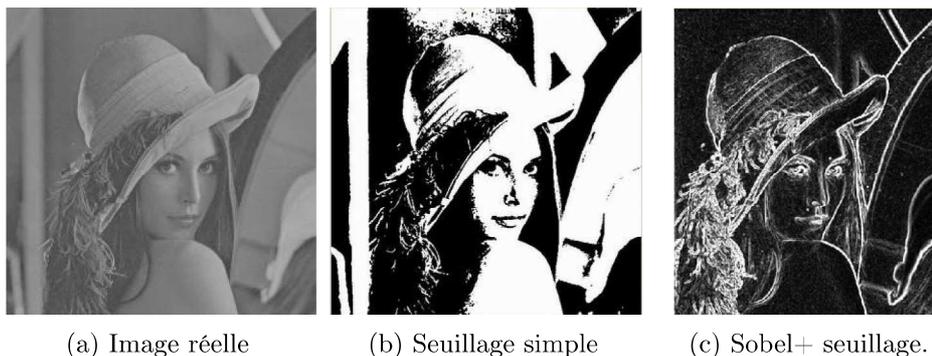


Figure 3.1: Comparaison de résultats de seuillage de l'image de Lena.

Pour les images contenant un fond uni et des objets, les régions correspondent ainsi aux objets dans la scène. Une illustration de ce cas d'application est présentée dans la figure 3.2 où on considère le cas d'une image astronomique. La segmentation en région est réalisée par un simple seuillage et la segmentation par contour est réalisée en utilisant l'opérateur de Canny.

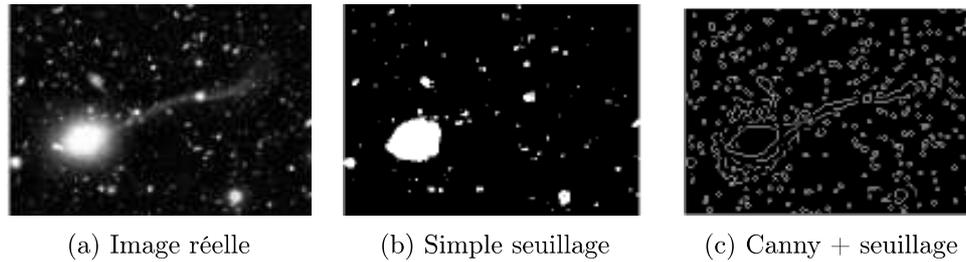


Figure 3.2: Comparaison de résultats de seuillage d'une image astronomique.

Dans la suite de notre travail, nous adoptons l'approche région qui fournit une prédétection automatique des objets. Nous proposons une approche de segmentation non supervisée pour détecter les objets présents dans une image naturelle.

Nous considérons que l'image est composée de deux classes évidentes : classe fond (en noir) et classe objet (en blanc). Nous étudions également les méthodes basées sur histogramme qui sont des méthodes de mise en œuvre assez simple et bien adaptées à ce cas d'utilisation.

3.2.3 Méthodes sur histogramme

L'histogramme d'une image est une courbe statistique calculée en déterminant la fréquence d'apparition de chaque niveau de gris g dans l'image ($p(g)$).

Les méthodes de segmentation sur histogramme reposent sur l'aspect spatial de l'information dans l'image. Le principe de ces méthodes consiste en la détermination des pics dans l'histogramme pour détecter les différentes classes. La difficulté majeure est la détermination du seuil optimal.

Dans la littérature, il existe plusieurs méthodes pour calculer les seuils. Nous citons, à titre d'exemples les méthode de pourcentage, la détection de vallées, la minimisation de variance, le seuillage entropique, etc [SS04, Abu89, M.C83].

Ces méthodes sont souvent parfaitement adaptées aux cas où l'image est composée de deux classes séparées. Cependant, lorsque l'image présente un seul pic, la distribution des données devient unimodale. Le seuillage d'une image unimodale est la méthode sur histogramme la plus courante pour la segmentation.

Dans la continuité de notre travail, nous nous intéressons au développement d'une méthode de segmentation d'une distribution unimodale qui se base sur l'histogramme. Ce choix est motivé par les deux raisons suivantes :

- L'histogramme est un outil précieux pour établir une valeur de seuil approprié. En effet, une utilisation judicieuse de l'histogramme permet de faire apparaître les différents détails et nuances acquises par le capteur de l'image ;
- L'histogramme permet de trouver d'une façon automatique le seuil de segmentation.

Le choix de la technique de seuillage nous permet de fixer notre approche de seuillage.

3.3 Techniques de binarisation et choix du seuil

Selon plusieurs travaux de recherche, les techniques de binarisation d'images en niveaux de gris peuvent être classées en deux catégories : seuillage global et seuillage local. D'autres techniques ajoutent un troisième groupe de méthodes hybrides, ces méthodes combinent des informations globales et locales pour attribuer les pixels à l'une des deux classes.

3.3.1 Seuillage global

C'est le type de seuillage le plus simple. Le seuillage global consiste à utiliser un seul seuil dans toute l'image pour la diviser en deux classes (objets et fond). Plusieurs techniques ont été développées pour déterminer le seuil sur l'histogramme dont on cite la méthode d'analyse discriminante¹.

Le principe du seuillage global pour une image I et un pixel de niveau de gris g est le suivant:

$$I(g) = \begin{cases} 0 & \text{si } I(g) < \text{seuil} \\ 1 & \text{si } I(g) \geq \text{seuil} \end{cases} \quad (3.2)$$

3.3.2 Seuillage local

Dans le seuillage local, les valeurs des seuils sont déterminés localement en considérant la valeur de chaque pixel ou d'un ensemble de pixels (une région). Les seuils ainsi trouvés dépendent fortement d'une caractéristique calculée dans une fenêtre de calcul. D'une manière générale, la valeur du seuil pour chaque pixel est calculée en fonction de la luminosité de son voisinage. Une difficulté principale dans ce type de seuillage réside dans le choix de la taille de la fenêtre de calcul.

3.3.3 Seuillage hybride

Dans l'approche hybride (appelée aussi seuillage adaptatif), l'image est divisée en des sous-images et la valeur de seuil est déterminée pour chaque sous image. Le seuillage adaptatif permet ainsi de déterminer les valeurs des seuils en combinant les caractéristiques globales et locales de l'image.

L'histogramme est souvent utilisé comme mesure globale et la caractéristique locale de l'image est calculée en considérant la moyenne des pixels de la fenêtre de calcul.

Généralement, le résultat de seuillage est une image binaire. Pour notre approche, nous utilisons le seuillage global. La figure 3.3 montre un exemple d'application du seuillage global sur une image médicale (image mammographique).

¹L'algorithme de seuillage par analyse discriminante permet de chercher la valeur de seuil en maximisant la séparabilité entre les deux classes.

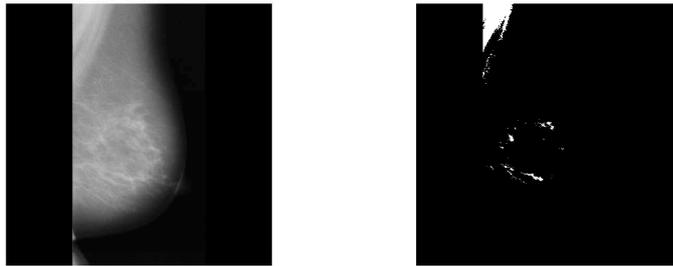


Figure 3.3: Seuillage global d'une image mammographique (seuil=170). L'image est de taille $(1024 \cdot 1024)$, la profondeur de l'image est 8 et le niveau de gris maximal est 248.

3.4 Seuillage d'une image unimodale

Dans de nombreux domaines d'applications civils et militaires, tels que : la détection (radar, sonar), l'astronomie, l'observation spatiale, la sismographie et la médecine; les images résultantes d'un simple seuillage présentent souvent la propriété d'avoir des zones d'intérêts de taille négligeable comparée à la classe fond. Ces images révélant une classe majoritaire ont un histogramme d'allure unimodale [MCMCFGCP05]. Une illustration de l'historgramme de l'image radar est présentée sur la figure 3.4.

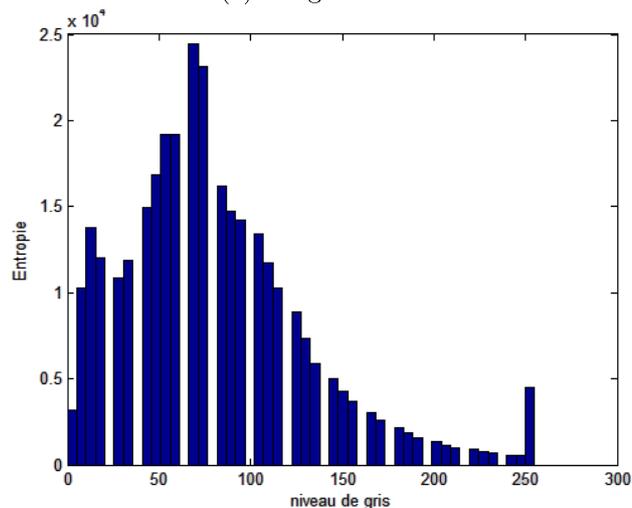
Une approche de segmentation commode pour ce type d'images est d'appliquer un algorithme de seuillage unimodal [NJU10, BDMV95]. Le but de ce seuillage consiste tout simplement à extraire les objets d'intérêt de leur fond. Cependant, la plupart des algorithmes de seuillage sont basés sur la recherche de zones de concavité dans l'historgramme, ce qui n'est pas évident dans le cas unimodal.

Considérant les difficultés dans le traitement des images présentant une distribution unimodale [NJU10], plusieurs techniques ont été proposées pour résoudre ce problème [MCMCFGCP05, SSWC88].

Nous présentons dans la suite une étude bibliographique sur les approches les plus intéressantes développées pour séparer les différentes classes dans une image unimodale. Cette étude nous permettra de positionner, dans la suite, notre approche proposée par rapport aux travaux existants dans la littérature.



(a) Image initiale



(b) Histogramme de l'image

Figure 3.4: Allure unimodale de l'histogramme de l'image radar.

3.4.1 Différentes approches existantes

Diverses techniques ont été proposées pour résoudre le problème de la détection des objets dans une image unimodale [NJU10]. Une première catégorie de ces approches propose de convertir le problème en la détection des objets dans une image bimodale (deux pics dans l'histogramme). Un exemple de ces travaux est celui de Weszka *et al.* [WNR74]. Weszka a proposé une technique permettant une analyse simple de l'histogramme des valeurs des intensités. La valeur du seuil est déterminée en calculant un minimum significatif de l'histogramme. L'approche de sélection du seuil est basée sur l'évaluation de la variation de la taille des pics et la sélection des vallées dans l'histogramme. Une autre approche permettant d'améliorer l'histogramme a été proposée dans [AR78]. La contribution dans ce travail consiste à utiliser les statistiques de second ordre pour déterminer la valeur du minimum de l'histogramme.

Une méthode différente a été proposée par Davis dans [DRW79]. Dans son travail, les relations statistiques entre les pixels et leurs voisinages sont exploitées pour choisir la valeur appropriée du seuil. Barratte *et al.* [BDMV95] ont développé une procédure de seuillage basée sur une série de transformations de l'image permettant d'avoir une image à histogramme bimodal.

Plus récemment, plusieurs techniques basées sur les méthodes de Otsu [Ots79], Hou *et al.* [HHN06] et Nakib *et al.* [NOS08] ont été développées. L'algorithme de Otsu permet de séparer une image donnée en deux classes. Selon Otsu, la valeur de seuil optimal maximise l'écart entre les classes objet et fond dans l'image. Les algorithmes de Hou *et al.* et Nakib *et al.*, quant à eux, se basent sur l'analyse statistique des pics de l'histogramme pour déterminer la valeur du seuil.

Une nouvelle plage de méthodes basées sur l'exploitation de la forme de l'histogramme est ensuite développée. Tsai dans [Tsa95] a développé une méthode permettant de localiser le maximum local dans la courbure de l'histogramme pour y détecter les discontinuités. Rosin [Ros01] a proposé une méthode différente basée sur la forme de l'histogramme. L'approche de Rosin est inspirée de celle du triangle de Zack *et al.* [15]. Dans son approche, une ligne droite est tracée à partir du maximum du niveau de gris de l'image jusqu'au point le plus élevé (pic) dans l'histogramme pour former un triangle (voir figure 3.5). La valeur du seuil considérée est celle qui correspond à l'abscisse du point d'intersection de la plus longue droite perpendiculaire à la ligne droite avec l'histogramme. Malgré les bons résultats dans de nombreux cas, la méthode de Rosin reste sensible à la statistique de l'histogramme et la position du point final.

Récemment, le seuillage entropique basé sur l'entropie de Shannon apparaît comme une nouvelle technique pour résoudre le problème de la sélection des seuils dans une image unimodale. Ce type de seuillage est appliqué dans de nombreuses approches de traitement d'images telles que la recherche et la reconnaissance des objets. Typiquement, l'application du seuillage entropique donne une meilleure segmentation mais présente une complexité de calcul supplémentaire.

Nous présentons dans la suite de ce paragraphe un ensemble de résultats de seuillage global d'une image sonar puis nous discuterons des travaux intéressants réalisés dans le cadre du seuillage entropique de l'image.

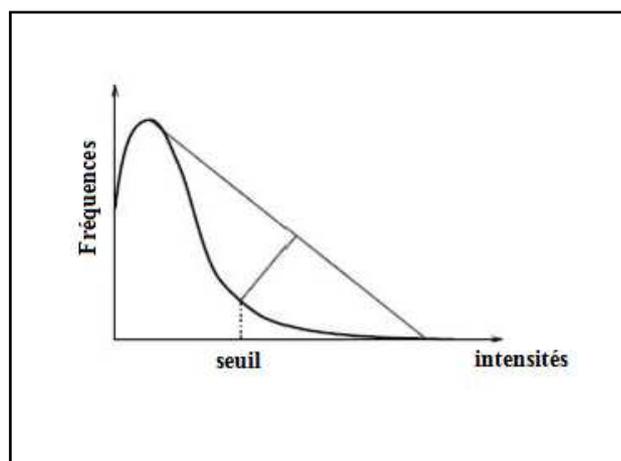


Figure 3.5: Seuillage unimodal par la méthode du triangle (Rosin).

3.4.2 Seuillage global automatique

Le principe de cette technique permet de segmenter l'image en deux classes (objet et fond) en supposant des modèles mathématiques pour les distributions (distribution gaussienne d'une manière générale). Le seuil de segmentation est déterminé de façon à réduire la probabilité d'erreur de classification dans les deux classes. Il existe plusieurs méthodes globales automatiques permettant de trouver un seuil à partir d'un histogramme. Les méthodes les plus connues sont Otsu, p-tile, Voorhees et Poggio et la méthode du triangle.

Dans cette partie, ces différentes techniques seront appliquées sur une image sonar de test préalablement filtrée par notre méthode de filtrage homomorphique. Nous prenons alors le cas de l'image sonar de test utilisée dans le chapitre précédent sur le prétraitement (figure 3.6).

Les propriétés statistiques de cette image sont les suivantes:

- La profondeur de l'image est de 16 bits par pixel ;
- La valeur minimale des niveaux de gris de l'image est égale à 2,9 ;
- La valeur maximale des niveaux de gris de l'image est égale à 18086 ;
- La moyenne des pixels est égale à 603,7.

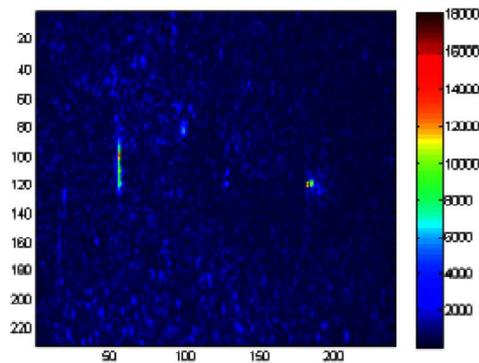


Figure 3.6: Image de test filtrée adoptée pour tester des méthodes de seuillage unimodal.

3.4.2.1 Seuillage de l'image sonar en utilisant la méthode d'Otsu

La méthode d'Otsu a pour objectif de trouver le seuil T permettant de diviser, d'une façon optimale, l'historgramme en deux segments. En d'autres termes, le but est de trouver la valeur de pixel qui maximise la variance inter-segments ou bien qui

minimise une mesure de variance intra-segments. Le calcul de la variance interclasses ou intra-classes est basé sur l'histogramme normalisé de l'image. L'implémentation de cette méthode pour le cas de l'image SAS de test (figure 2.8), permet de trouver une valeur de seuil $T = 9007,6$. La figure 3.7 présente une illustration de résultat de seuillage de l'image par cette valeur.

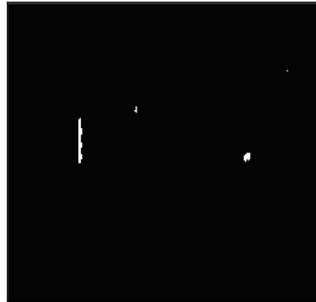


Figure 3.7: Application de la méthode d'Otsu pour le seuillage de l'image SAS de test.

3.4.2.2 Méthode de "p-tile"

Pour séparer les deux groupes de l'histogramme, une simple méthode de seuillage nommée "p-tile" peut être utilisée. Le principe de cette méthode se base sur les hypothèses que les objets sont plus clairs que l'arrière plan de l'image et qu'ils occupent un pourcentage fixe de la zone image. Un inconvénient majeur de cette approche est qu'elle nécessite des connaissances *a priori* sur le pourcentage de chaque classe dans l'image. Si on suppose que la classe écho présente 20% de la taille de l'image, le seuil trouvé en appliquant cette méthode sur l'image sonar de test est $T = 6300$.

Le résultat de seuillage en utilisant la valeur T trouvée est présenté sur la figure 3.8.

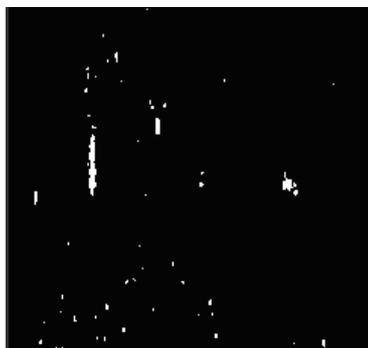


Figure 3.8: Application de la méthode de p-tile ($p=20\%$) pour le seuillage de l'image SAS de test.

3.4.2.3 Méthode de Voorhees et Poggio

Voorhees et Poggio [VP88] ont développé une technique de seuillage automatique de l'histogramme unimodal basée sur la modélisation statistique du gradient de l'image par la loi de Rayleigh. Le résultat d'application de cette méthode dans le cadre de notre image permet de trouver une valeur de seuil $T = 10675$ et une image binaire présentée dans la figure 3.9.

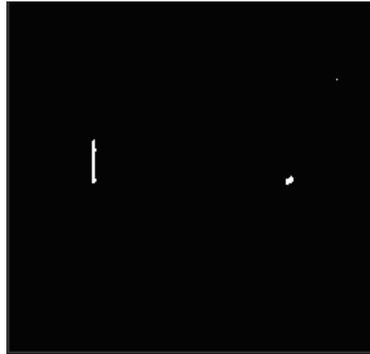


Figure 3.9: Application de la méthode de Voorhees et Poggio pour le seuillage de l'image SAS de test.

3.4.2.4 Méthode de triangle

Une autre méthode de seuillage encore plus récente (2001) se base sur l'allure de l'histogramme et appelée la méthode de triangle à été proposée par Rosin et inspirée par l'algorithme de triangle de Zack (1977). Le seuil est sélectionné sur le point de l'histogramme qui maximise la distance perpendiculaire de l'histogramme et la droite qui passe par le maximum de niveau de gris de l'image. Pour le cas de notre image de test, l'implémentation de cette technique permet de trouver une valeur de seuil $T = 9081,9$ et un résultat de seuillage présenté sur la figure 3.10.



Figure 3.10: Application de la méthode de triangle pour le seuillage de l'image SAS de test.

Pour déterminer les seuils à partir d'histogrammes unimodaux, certaines méthodes exploitent les propriétés statistiques de l'image (Voorhees et Poggio), d'autres méthodes se basent sur l'analyse de la forme de l'histogramme (méthode de Triangle) ou la composition initiale de l'image (méthode de p-tile). La méthode la plus populaire est celle de Otsu. Dans la littérature, il existe plusieurs autres techniques de seuillage unimodal [MCMCFGCP05, SSWC88]. Cependant, des études ont montré que toutes ces approches ne permettent pas de donner des résultats optimaux face à des conditions différentes (données bruitées, faible contraste, . . .) [WNR74].

Le seuillage entropique est une technique différente dérivée de la théorie de l'information qui présente aujourd'hui un intérêt particulier pour la segmentation des images [KSW85, Pun81]. Nous présentons dans la suite notre approche de segmentation basée sur l'entropie de Shannon.

3.5 Étude théorique de l'approche de segmentation

L'objectif de notre approche est de fixer le seuil de segmentation pour un histogramme unimodal et de tester la méthode dans le cas des images réelles filtrées. Dans la littérature, plusieurs travaux de recherche se sont intéressés au critère de l'entropie pour la segmentation des images. Les algorithmes de segmentation se basent le plus souvent sur la maximisation de l'entropie de Shannon [LL94, Abu89, KSW85, SA04]. L'idée de notre travail se base sur le calcul de la perte en entropie lorsque l'on ne considère que la classe objets dans l'image.

Dans un premier temps, nous définissons la méthode de binarisation que nous adopterons. En analysant la courbe de variation de l'entropie en fonction du seuil de segmentation et compte tenu de la méthode de binarisation ainsi définie, nous pourrions extraire les paramètres de calcul du seuil de segmentation. Étant donné que le critère de l'entropie permet d'évaluer la dispersion des valeurs, la détermination de la valeur du seuil repose sur l'organisation et la forme de la courbe et non sur les valeurs individuelles du niveau de gris. Dans un deuxième temps, nous réalisons une étude des variations de la fonction pour déterminer le seuil global de segmentation de l'histogramme unimodal. La méthode implémentée est testée dans le cas particulier de l'image sonar (image SAS) et sur des images synthétisées renfermant chacune un nombre d'objets différent. Les résultats de ces tests ainsi que les différentes analyses et conclusions sont représentés dans la dernière partie de ce chapitre.

Toutefois, une autre étude de l'approche proposée dans un domaine différent (le domaine médical) est réalisée. Les détails de cette étude seront présentés dans le chapitre 5.

3.5.1 Seuillage entropique

Le seuillage entropique est une technique de segmentation automatique de l'histogramme. Le principe de ce seuillage se base sur l'utilisation de l'entropie de Shannon [LL94] comme critère pour détecter le seuil de segmentation de l'image. Généralement, les algorithmes de segmentation exploitant les propriétés de l'entropie reposent

sur la maximisation de l'entropie de Shannon. En effet, l'entropie de Shannon mesure la quantité d'information dans une entité donnée. Considérant un nombre connu de classes, le but est de maximiser la quantité d'information dans chacune des classes résultantes.

Ainsi, lorsque l'histogramme de l'image présente n pics, les valeurs de seuils sont fixées de sorte que l'entropie résultante de découpage de l'histogramme en n soit maximale.

Le premier travail de seuillage entropique a été introduit par Pun [Pun81]. Dans son travail, Pun a proposé deux algorithmes intéressants fondés sur l'utilisation de l'entropie pour déterminer le seuil de segmentation dans l'image. Plus tard, ce travail a été amélioré par Kapur *et al.* [KSW85]. L'inconvénient majeur est que la corrélation spatiale de l'image n'est pas considérée dans ces algorithmes. En conséquence, deux images différentes ayant le même histogramme auront également le même seuil de segmentation.

Plus tard, d'autres méthodes de seuillage entropique ont été développées. Ces méthodes reposent souvent sur les travaux de Kapur, Sahoo et Wong [LCC01]. De nombreux travaux ultérieurs [SA04, SA06] ont proposé d'utiliser l'entropie à deux dimensions pour améliorer le seuillage. Ces approches donnent une meilleure segmentation mais présentent une complexité de calcul supplémentaire.

Dans la deuxième partie de ce chapitre, nous détaillons notre approche basée sur l'entropie de Shannon que nous testons dans le cadre de l'imagerie sonar.

3.5.2 Entropie et hypothèses de calcul

L'entropie est calculée en utilisant la méthode de Shannon, son expression est définie comme suit:

$$H(x) = - \sum_{i=1}^N P_i \cdot \log_2(P_i) \quad (3.3)$$

avec N la taille de l'image en pixels et P_i la probabilité d'apparition de pixels de niveau de gris i dans l'image.

Considérant le cas de la distribution unimodale (un exemple est présenté dans la figure 3.11) et la méthode de binarisation prédéfinie, nous supposons alors qu'il existe une certaine valeur de seuil s telle que :

- Pour toute valeur de seuil $x < s$ on a :

$$H(x) = - \sum_{i=1}^N P_i \cdot \log_2(P_i) = - \sum_{i=1}^{N_{bruit}} P_i \cdot \log_2(P_i) \approx 0 \quad (3.4)$$

- si $x > s$ on a:

$$H(x) = - \sum_{i=1}^N P_i \cdot \log_2(P_i) = - \sum_{i=1}^{(s-1)} P_i \cdot \log_2(P_i) - \sum_{i=s}^{N_{obj}} P_i \cdot \log_2(P_i) \quad (3.5)$$

avec N_{bruit} et N_{obj} respectivement les nombres du niveau de gris de la classe fond et de la classe objets dans l'image initiale.

Pour étudier les variations faibles mais significatives de l'entropie dans l'image initiale, nous commençons par définir la méthode de binarisation suivante : Pour chaque valeur de seuil, le calcul de la valeur de l'entropie est réalisé en admettant que :

- Les pixels de l'image avec un niveau de gris inférieur au seuil prennent la valeur 0 ;
- Les pixels avec un niveau de gris supérieur au seuil gardent la même valeur que dans l'image initiale.

L'hypothèse 3.4 est justifiée par la définition de l'entropie : l'image segmentée ne contient que des valeurs de moyenne nulle donc l'entropie est minimale et sa valeur approximative est quasiment nulle. Selon notre méthode de binarisation, lorsque la valeur de seuil est supérieure à s , l'entropie de la classe fond est quasiment nulle. L'entropie finale est donc donnée par uniquement la classe objet (hypothèse 3.5). Le seuil optimal pour séparer les deux classes (fond et objets d'intérêt dans l'image) est nommé "seuil d'activation". La position approximative de cette valeur est définie par le niveau de gris du pixel qui fait augmenter d'une façon importante l'entropie de l'image.

Compte tenu de cette description, la courbe de variation de l'entropie résultante de l'application de la méthode de binarisation devrait posséder donc une allure semblable à celle présentée dans la figure 3.12. D'après la courbe, nous pouvons distinguer trois phases distinctes.

1. Phase d'absence des objets d'intérêt ;
2. Phase d'apparition accélérée des objets d'intérêt ;
3. Phase de présence de tous les objets d'intérêt présents dans l'image.

Il est à noter que lorsque l'image initiale ne contient pas des objets d'intérêt, l'histogramme de l'image aurait évidemment une distribution unimodale contenant uniquement la classe fond. Cependant, l'allure de la courbe serait une droite de valeur constante égale à l'entropie de l'image.

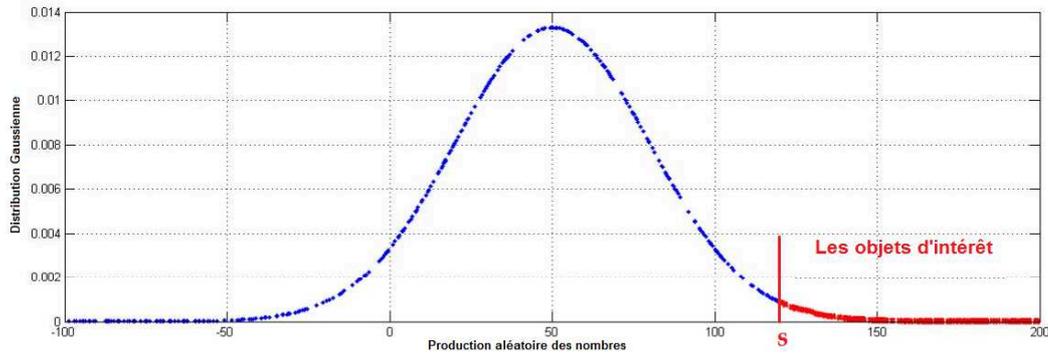


Figure 3.11: Distribution unimodale.

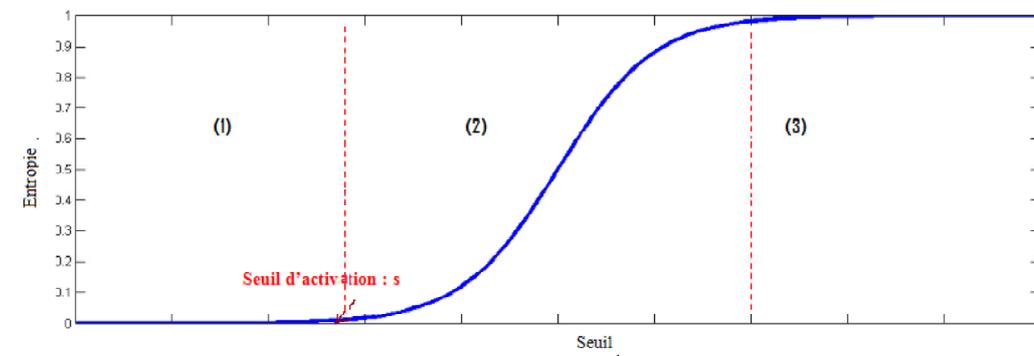


Figure 3.12: Position approximative du seuil d'activation dans la courbe de perte en entropie.

3.5.3 Variation de l'entropie en fonction du seuil de segmentation

Nous construisons la courbe de variation de l'entropie pour des valeurs de seuil différentes en allant du niveau de gris minimal au niveau de gris maximal de l'image et en utilisant la méthode de binarisation préalablement définie.

L'allure de la courbe résultat pour le cas de l'image SAS filtrée est présentée dans la figure 3.13.

La courbe présentée dans la figure 3.13 montre que pour certaines valeurs de seuils de segmentation, l'entropie est quasiment constante et égale à 0. À partir d'un certain niveau de gris, l'entropie de l'image augmente en valeur d'une manière considérable pour atteindre la valeur de l'entropie de l'image initiale. La valeur de pixel correspondante au déclenchement de cette variation peut être considérée comme le seuil d'activation pour la segmentation ; c'est-à-dire la valeur qui justifie les hypothèses décrites dans la partie précédente (hypothèses 3.4 et 3.5). Autrement dit, ce niveau de gris coïncide avec le seuil de segmentation recherché qui, au-delà de sa valeur, commence la segmentation du fond de l'image.

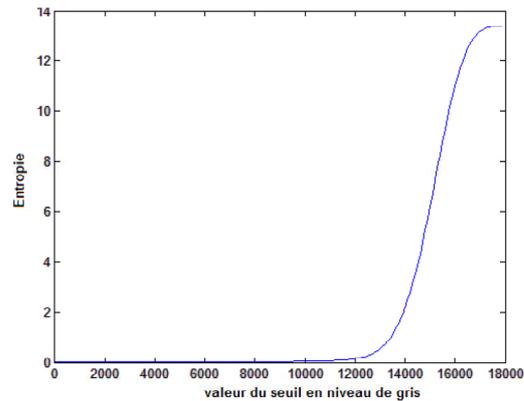


Figure 3.13: Illustration de la courbe de la perte en entropie en fonction de la valeur de seuil.

D'autre part, le comportement de la fonction de mesure de l'entropie ressemble à une sigmoïde. En effet la normalisation de la courbe de l'entropie (la valeur de l'entropie dans chaque image est divisée par l'entropie de l'image initiale) permet d'avoir une courbe sigmoïde qui possède pour asymptotes les droites d'équations $y = 0$ et $y = 1$.

3.5.4 Fonction Sigmoïde

D'une manière générale, une sigmoïde est une fonction logistique définie par l'expression de la forme:

$$f(x) = \frac{1}{1 + \exp(-\lambda x)} \quad (3.6)$$

Pour une courbe sigmoïde de paramètre λ , la tangente au point d'inflexion est $\lambda/4$. Cette propriété permet de déterminer facilement le paramètre d'une sigmoïde en observant la pente au point d'inflexion. Une autre propriété intéressante de la fonction sigmoïde est sa symétrie par rapport au point d'inflexion où $\frac{d^2 f}{dx^2} = 0$.

Typiquement, les propriétés de la fonction sigmoïde s'expliquent par celles de sa dérivée. Ainsi, le dépouillement de la courbe de variation de l'entropie en fonction du seuil de segmentation, et en considérant les propriétés de variation de la fonction sigmoïde, pourra aider à préciser la valeur du seuil de segmentation pour l'image filtrée.

3.6 Seuillage entropique et pré-détection des objets d'intérêt

3.6.1 Estimation de la courbe d'entropie

Pour comparer l'allure de la fonction d'entropie obtenue dans le cas de l'image SAS de test avec celle d'une sigmoïde, nous avons présenté les deux courbes dans le même repère.

Une fonction de changement d'échelle a été appliquée sur la fonction entropie normalisée. Le résultat de comparaison entre les deux courbes est présenté sur la figure 3.14.

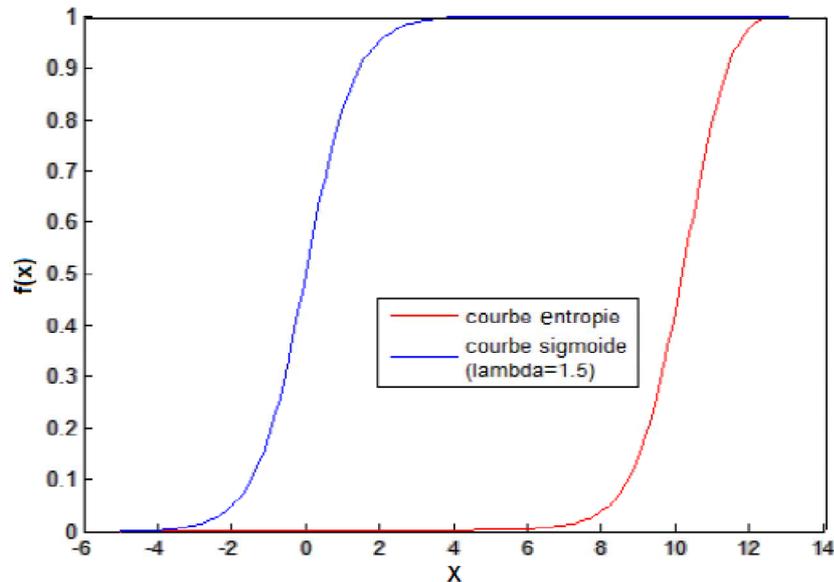


Figure 3.14: Allure de la courbe d'entropie très proche de celle d'une sigmoïde.

La courbe de calcul de perte en entropie est la transformée d'une sigmoïde par une translation dont le vecteur déplacement est à définir. Ainsi, nous définissons la fonction logistique d'estimation de la courbe d'entropie par l'expression suivante :

$$f(x) = \frac{1}{(1 + \exp(-\lambda(x - t)))} \quad (3.7)$$

où t est la valeur de translation.

Notre idée pour le calcul de chacun des deux paramètres t et λ est d'appliquer la méthode de l'erreur quadratique moyenne EQM² à deux reprises ; d'abord pour déterminer la valeur du paramètre t et ensuite pour trouver le paramètre λ le plus approprié à la fonction tradlatée.

L'estimation de chacun des paramètres est alors effectuée par minimisation de l'erreur quadratique entre la courbe modélisée et la courbe réelle.

Dans un premier temps, nous utilisons une valeur fixe de paramètre lambda (choix de λ moyenne = 2). Le choix de cette valeur de paramètre lambda est un choix arbitraire justifié par le fait que pour une valeur quelconque de λ et pour le même vecteur de translation t , la sigmoïde est symétrique par rapport à son point d'inflexion.

La figure 3.15 présente le résultat de modélisation de la courbe d'entropie résultante, pour l'image SAS de test, par différentes fonctions sigmoïdes après estimation

²en anglais *Mean Squared Error* : grandeur très utile pour comparer les estimateurs entre eux. Le meilleur estimateur est celui qui présente l'EQM la plus faible. Soit $\hat{\theta}$ un estimateur de θ ; L'erreur quadratique moyenne est définie par $EQM(\hat{\theta}) = E(\hat{\theta} - \theta)^2$

de la valeur du paramètre t .

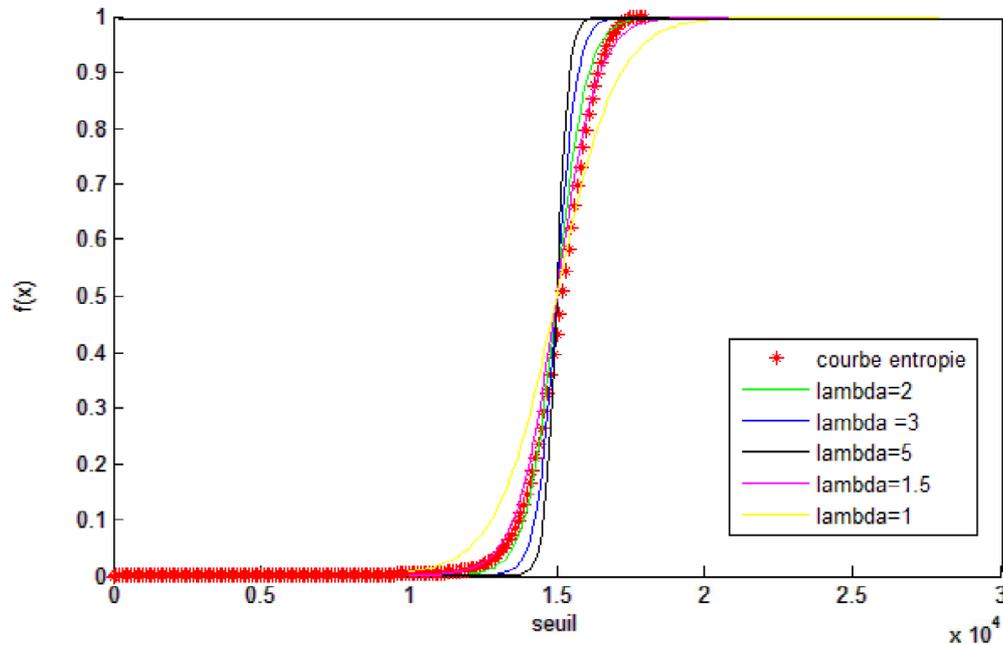


Figure 3.15: Estimation de la courbe d'entropie par différentes fonctions sigmoïdes pour le cas de l'image réelle de test.

En appliquant la méthode de l'erreur quadratique moyenne sur la fonction sigmoïde translaturée, on obtient alors les paramètres estimés comme suit : $\lambda = 1,63$ et $t = 10,3$. La visualisation de la courbe d'entropie et sa courbe estimée est présentée sur la figure 3.16 .

3.6.2 Étude des variations de la fonction d'estimation et seuillage de l'image sonar.

Sachant que le seuil d'activation de la courbe de l'entropie coïncide avec le niveau de gris d'apparition des objets dans l'image concernée et que la courbe de l'entropie est désormais une sigmoïde translaturée de paramètre $t = 10,3$ et $\lambda = 1,63$, nous pouvons alors calculer les fonctions dérivée première et dérivée seconde de la sigmoïde résultante.

D'autre part, la fonction estimée est caractérisée par un point d'inflexion et la courbe traverse sa tangente en ce point. Ce point est aussi détectable lorsque la dérivée seconde s'annule en changeant de concavité.

Nous traçons les deux fonctions dérivées de la courbe d'entropie estimée que nous présentons sur la figure 3.17.

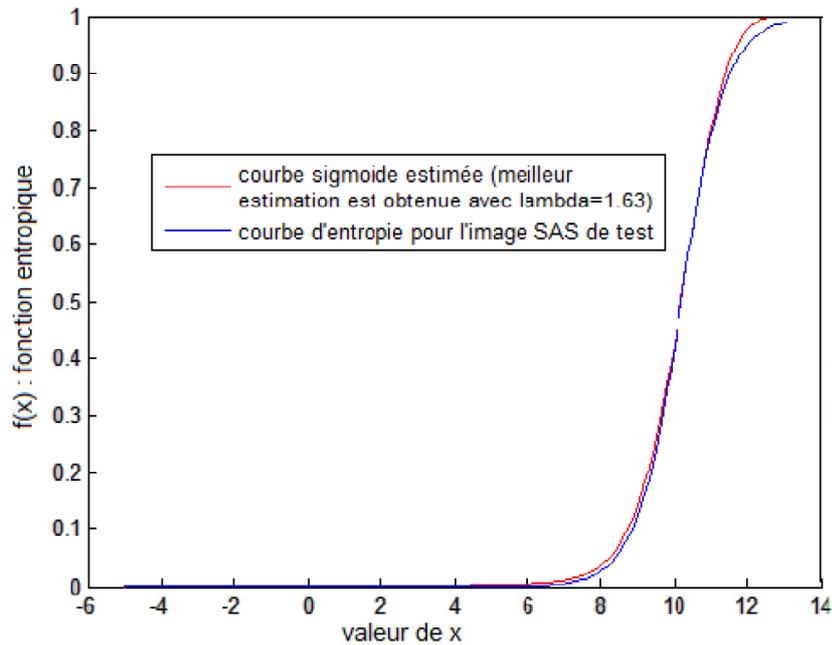
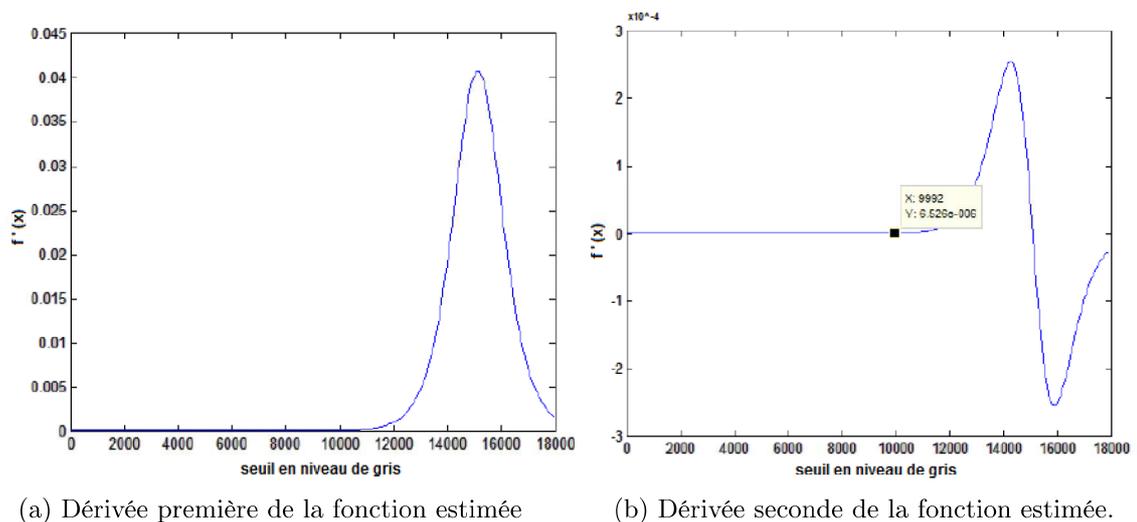


Figure 3.16: Application de la méthode de l'EQM de la deuxième étape : modélisation finale de la courbe de l'entropie.



(a) Dérivée première de la fonction estimée

(b) Dérivée seconde de la fonction estimée.

Figure 3.17: Variations des dérivées 1^{re} et 2^e de la fonction sigmoïde estimée dans le cas de l'image de test.

Considérant toujours le cas d'image sonar, nous supposons que la valeur calculée du point d'inflexion coïncide avec le niveau de gris moyen des pixels des échos présents dans l'image (pour ce point, on suppose qu'approximativement la moitié des

pixels de la classe objets de l'image sont dévoilés). Ainsi, selon notre raisonnement la valeur du seuil de segmentation est inférieure à celle du point d'inflexion et l'écart mesuré est donné par la formule suivante:

$$Ecart = max(g) - E(g(o)) \quad (3.8)$$

avec $max(g)$ réfère à la valeur maximale de niveau de gris g dans l'image et $E(g(o))$ la valeur moyenne des pixels de la classe objets (ou encore la valeur du point d'inflexion).

D'une manière différente, le seuil global de segmentation s de l'image peut être calculé selon l'expression suivante :

$$s = 2 \cdot E(g(o)) - max(g) \quad (3.9)$$

L'implémentation des différentes étapes de l'algorithme de segmentation, en considérant l'image sonar de test, permet de trouver une valeur numérique du seuil égale à 9140. Le résultat du seuillage est présenté sur la figure 3.18.

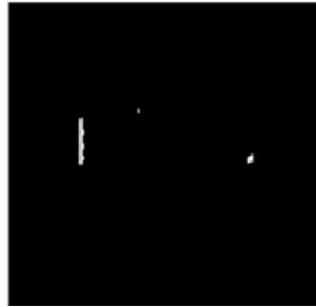


Figure 3.18: Résultat du seuillage de l'image SAS par la valeur calculée de seuil ($s=9140$)

L'application de la méthode de seuillage permet de dévoiler la plupart des objets d'intérêt présents dans l'image vérité terrain (figure 3.19). Les objets posés sur le fond marin sont détectés par le seuil trouvé (objet (a)). D'autre part, le seuillage ne révèle pas de fausses détections et présente des résultats proches de celles des approches de Otsu et de Voorhees, très utilisées pour le seuillage unimodal (étude réalisée dans le paragraphe 3.4.2).

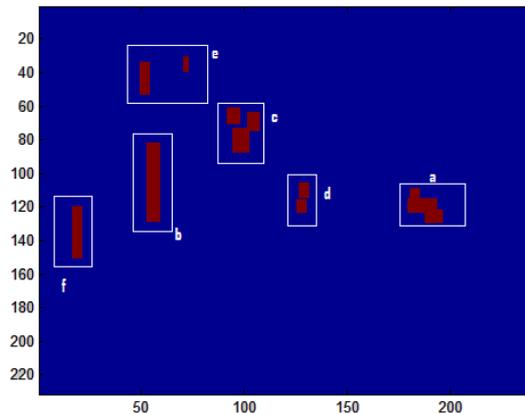


Figure 3.19: Vérité terrain de l'image sonar de test

Dans la suite, nous exploiterons les propriétés de notre approche de segmentation pour étudier le cas particulier de la détection des objets rares.

3.6.3 Algorithme de pré détection des objets d'intérêts

Dans le but d'examiner la performance de notre méthode de segmentation sur le plan local, nous procédons à l'utilisation d'une fenêtre de calcul nous permettant de subdiviser l'image initiale en des sous-images de taille égale. Ainsi, nous appliquons l'algorithme de segmentation suivant:

- Fixer la taille de la fenêtre de calcul avec laquelle on parcourt l'image. La taille de la fenêtre doit être suffisamment grande par rapport à la taille approximative des objets ;
- Pour chaque sous-image on applique les étapes de l'algorithme de segmentation suivantes :
 1. Calculer l'erreur quadratique moyenne (EQM) pour déterminer la valeur de t ;
 2. Calculer l'EQM pour déterminer la valeur de λ . Dans cette étape, la fonction des moindres carrés permet de réduire le carré de l'erreur entre les données initiales et les valeurs prédites par l'équation translatée ;
 3. Déterminer la valeur du seuil optimisé (seuil d'activation) en exploitant les propriétés du point d'inflexion et de la fonction dérivée seconde.
- Comparer la valeur de λ local avec une valeur seuil (que nous fixons manuellement à 0,8) pour conclure si la région visitée contient des objets d'intérêt.

Pour évaluer les performances de la méthode de segmentation en utilisant la fenêtre de balayage, nous appliquons notre algorithme sur l'image sonar de test. La figure 3.20 présente le résultat de classification de l'image initiale en une première classe susceptible de contenir des objets (régions claires) et une deuxième classe désignant la partie fond de l'image (régions sombres).

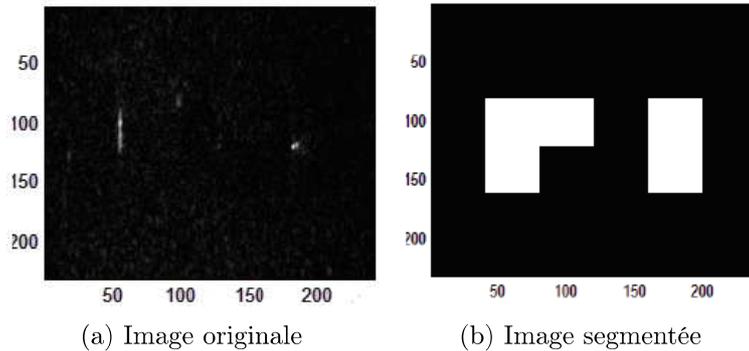


Figure 3.20: Seuillage local de l'image sonar en utilisant une fenêtre de taille 40×40 .

Le résultat des différentes implémentations est considéré important pour la suite de notre travail. En effet, l'application des prochaines approches de détection des événements rares, ne nécessitera pas désormais l'exploitation de toute l'image de test et sera ainsi limitée sur des zones appartenant à la classe 1 (zones claires).

3.7 Variations de λ en fonction du pourcentage d'occupation en objets de l'image

Arrivé à ce stade, nous cherchons à définir une grandeur probabiliste nous permettant de juger l'occupation ou non de l'image de synthèse par des événements rares ($<1\%$) en se basant sur la valeur de λ estimée. Ainsi, on effectue une étude du paramètre de la fonction sigmoïde estimée en fonction du pourcentage de l'occupation de l'image avec des objets.

Pour pallier la difficulté de l'insuffisance des données sonar disponibles, nous réalisons notre étude expérimentale sur des images de synthèse. Ces images sont synthétisées en prenant en compte le cas réel (écart type et moyenne de l'image sonar). De plus, toutes ces images présentent une allure unimodale de leur histogramme et contiennent un nombre différent des objets. Afin de restreindre le nombre des tests effectués, nous admettons que la taille des objets présents dans l'image ne doit pas dépasser 1% de la taille de l'image initiale. Ces conditions nous permettent d'adhérer le problème de détection des objets rares dans une image sonar.

Dans la pratique, la partie fond de l'image de synthèse est simulée par la fonction "*randn*" de Matlab. Pour des résultats plus rigoureux, nous procédons à réaliser chaque expérimentation sur un échantillon d'images de taille égale à 100 et de considérer uniquement les résultats donnés par la moyenne de l'échantillon.

Dans ce travail, nous mesurons également la force du signal comparée à celle du bruit de fond par l'intermédiaire du critère d'évaluation : rapport signal sur bruit (*Signal Noise Ratio* : SNR). Le SNR d'une image sonar est défini par le rapport des énergies des échos et du fond. L'énergie du signal est représentée par sa valeur moyenne μ , et celle du bruit par l'écart-type σ . L'expression de calcul de SNR est

78 Chapitre 3. Segmentation des images : pré-détection des objets rares

la suivante :

$$SNR = 10 \cdot \log_{10}\left(\frac{\mu}{\sigma}\right) \quad (3.10)$$

Pour une image ne contenant aucun objet, la valeur de SNR est infinie. Les résultats d'évaluation d'un échantillon contenant 100 images, synthétisées par une distribution normale, sont présentés dans le tableau 3.1.

Image i	Entropie initiale	Entropie finale	λ
image 1	12,06	14,50	0,6
image 2	12,11	14,50	0,61
image 3	12,08	14,48	0,61
⋮	⋮	⋮	⋮
image 44	12,09	14,47	0,62
image 45	12,10	14,54	0,57
image 46	12,11	14,53	0,58
image 98	12,12	14,52	0,59
image 99	12,12	14,43	0,65
image 100	12,12	14,48	0,62
Moyenne	12,10	14,49	0,61

Tableau 3.1: Résultats de simulation d'un échantillon de 100 images ne contenant aucun objet.

Dans la suite, nous présentons les résultats de simulation des images contenant respectivement un (tableau 3.2), deux (tableau 3.3), trois (tableau 3.4), six (tableau 3.5) et vingt objets (tableau 3.6). Pour chaque test effectué, nous calculons la valeur moyenne de paramètre λ et le SNR pour un échantillon contenant 100 images.

Image i	Entropie initiale	Entropie finale	SNR	λ
image 1	11,51	14,23	8,79	0,79
image 2	10,94	13,89	10,95	1,09
image 3	10,84	13,88	11,18	1,1
⋮	⋮	⋮	⋮	⋮
image 25	10,85	13,88	11,18	1,1
image 26	11,05	13,97	10,51	1,01
image 27	10,84	13,87	11,15	1,11
image 28	10,23	13,55	13,17	1,46
⋮	⋮	⋮	⋮	⋮
image 98	10,97	13,97	10,65	1,01
image 99	11,05	13,98	10,44	1
image 100	11,54	14,23	8,81	0,79
Moyenne	10,96	13,93	10,80	1,06

Tableau 3.2: Résultats de simulation d'un échantillon de 100 images contenant un seul objet.

3.7. Variations de λ en fonction du pourcentage d'occupation en objets de l'image

79

Image i	Entropie initiale	Entropie finale	SNR	λ
image 1	9,99	13,38	13,45	1,67
image 2	9,99	13,38	15,01	1,68
image 3	10,72	13,82	10,04	1,15
⋮	⋮	⋮	⋮	⋮
image 22	10,16	13,49	14,13	1,53
image 23	10,37	13,61	12,07	1,39
image 24	10,80	13,85	10,04	1,12
⋮	⋮	⋮	⋮	⋮
image 97	9,74	13,24	14,93	1,87
image 98	10,63	13,74	11,50	1,24
image 99	10,25	13,55	12,51	1,46
image 100	9,78	13,30	15,01	1,79
Moyenne	10,26	13,54	13,21	1,49

Tableau 3.3: Résultats de simulation d'un échantillon de 100 images contenant deux objets.

Image i	Entropie initiale	Entropie finale	SNR	λ
image 1	9,90	13,35	13,33	1,71
image 2	10,38	13,60	12,07	1,39
⋮	⋮	⋮	⋮	⋮
image 15	10,83	13,85	11,35	1,13
image 16	10,00	13,39	13,72	1,65
image 17	9,58	13,18	15,31	1,96
⋮	⋮	⋮	⋮	⋮
image 98	9,86	13,31	15,31	1,78
image 99	10,31	13,58	12,87	1,43
image 100	9,39	13,039	16,86	2,19
Moyenne	9,88	13,32	14,63	1,78

Tableau 3.4: Résultats de simulation d'un échantillon de 100 images contenant trois objets.

Image i	Entropie initiale	Entropie finale	SNR	λ
image 1	9,14	12,91	18,25	2,43
image 2	8,77	12,68	19,23	2,91
image 3	9,10	12,88	17,09	2,49
\vdots	\vdots	\vdots	\vdots	\vdots
image 60	9,21	12,95	17,39	2,34
image 61	8,85	12,73	19,37	2,79
image 62	9,17	12,91	16,45	2,41
image 63	9,07	12,88	17,79	2,49
image 64	9,40	13,06	18,00	2,17
\vdots	\vdots	\vdots	\vdots	\vdots
image 98	9,40	13,02	16,05	2,23
image 99	8,85	12,73	18,54	2,79
image 100	9,08	12,87	17,50	2,5
Moyenne	9,17	12,91	17,44	2,43

Tableau 3.5: Résultats de simulation d'un échantillon de 100 images contenant six objets.

Image i	Entropie initiale	Entropie finale	SNR	λ
image 1	7,41	11,86	26,03	5
image 2	7,47	11,88	26,16	5
image 3	7,56	11,93	24,88	5
image 4	7,44	11,87	25,35	5
\vdots	\vdots	\vdots	\vdots	\vdots
image 50	7,57	11,90	24,78	4,96
image 51	7,30	11,76	26,42	5
image 52	7,27	11,76	26,50	5
image 53	7,47	11,88	25,18	5
\vdots	\vdots	\vdots	\vdots	\vdots
image 98	7,24	11,72	26,50	5
image 99	7,31	11,79	25,92	5
image 100	7,26	11,73	25,77	5
Moyenne	7,42	11,85	25,56	4,96

Tableau 3.6: Résultats de simulation d'un échantillon de 100 images contenant vingt objets.

D'une manière générale, les résultats de notre étude appliquée sur un ensemble d'images synthétisées dans le cas sonar par les trois lois statistiques (normale, Weibull et de Rayleigh) montrent une certaine corrélation entre les paramètres étudiés. En effet, il existe une certaine corrélation entre le paramètre de la sigmoïde et le SNR de l'image. Lorsque le nombre des objets dans l'image augmente,

le paramètre de la sigmoïde augmente aussi et la valeur de SNR devienne plus significative. Cependant pour une amplitude maximale du signal dans l'image proche de 1%, la valeur de SNR reste toujours faible (inferieur à 20db).

La figure 3.21 montre les résultats de variation de λ en fonction de $PSNR$. Ces résultats sont obtenus pour échantillon synthétisé par une distribution normale.

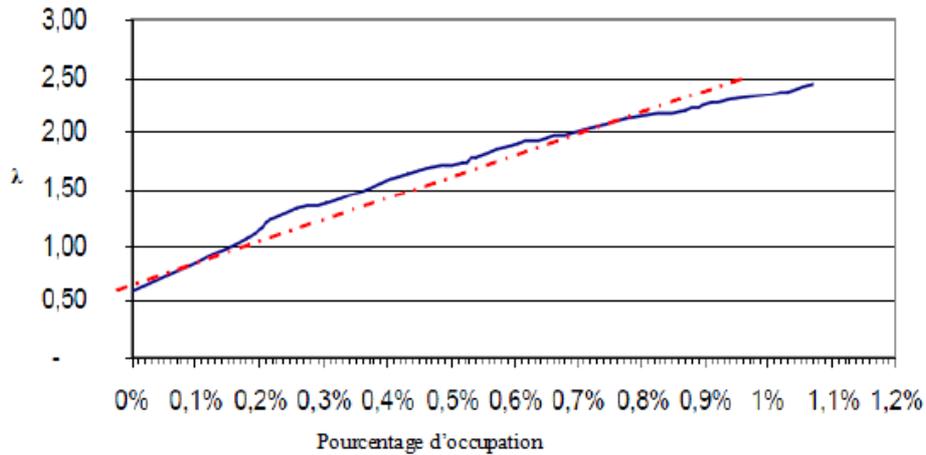


Figure 3.21: Variation de taux d'occupation des objets en fonction du paramètre λ (cas des images synthétisées par la loi normale).

La courbe de variation de λ en fonction du nombre des objets a une caractéristique linéaire. Ainsi, il existe un paramètre (pente de la courbe) qui permet, connaissant le nombre d'objets dans l'image, d'estimer la valeur de λ . Cette conclusion nous permet de déduire la probabilité de présence d'un objet dans une image unimodale en déterminant sa courbe de l'entropie.

Suite à une étude comparative des méthodes d'estimation, nous proposons d'utiliser la méthode de régression linéaire d'ordre 1³ pour une bonne estimation des paramètres de la courbe. Ensuite, nous calculons la droite de régression moyenne pour les trois distributions considérées.

Nous appliquons une stratification de niveau 5% et 95% pour identifier les images de forte ou moyenne ou faible probabilité de présence des objets. Puis dans la suite, nous travaillons sur l'optimisation de choix du seuil pour augmenter les performances de détection.

La figure 3.22 présente le résultat d'estimation de la droite d'évolution moyenne de λ en fonction du pourcentage d'occupation des objets pour l'ensemble des images synthétisées.

³Le principe de la régression linéaire du premier ordre est d'expliquer et modéliser une variable X par une fonction affine d'une autre variable Y . Le lien entre les deux variables X et Y est modélisée par une fonction affine ($Y = \alpha X + \beta$). Ce lien est alors représenté graphiquement par une droite.

À ce stade, nous cherchons à définir une valeur probabiliste qui nous permet de déterminer si l'image est occupée par des objets d'intérêt en observant la valeur de λ estimée. Nous effectuons un test d'hypothèse statistique avec une valeur de risque initialement fixée à 5% pour juger de la présence des objets dans l'image.

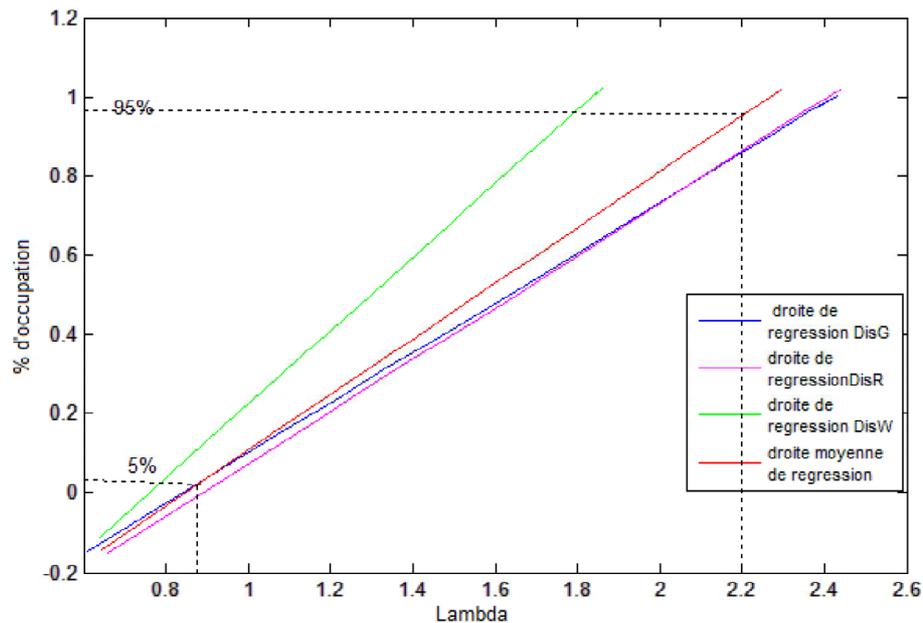


Figure 3.22: Droite de régression moyenne estimant la variation du paramètre de la sigmoïde en fonction du pourcentage d'occupation des images par des objets d'intérêt.

Ainsi, nous distinguons deux classes : classe absence et classe présence des objets d'intérêt.

Sur la figure 3.23, nous présentons un échantillon de trois images de synthèse contenant chacune une probabilité différente de présence d'objets (toujours inférieure à 1), que, selon la valeur de λ , nous distinguons trois types de résultat : image de faible, moyenne ou forte probabilité de présence d'objets d'intérêts.

3.8 Tests et évaluation des performances

Pour évaluer notre algorithme de pré-détection, nous réalisons un ensemble de tests sur 7965 images de synthèse contenant chacune un nombre différent d'objets. Pour chaque valeur de α nous résumons les résultats obtenus par la matrice de confusion. Considérant le cas de deux classes (présence d'objet / absence d'objet), cette matrice (voir tableau 3.7) peut être exprimée par les termes suivants :

- VDP : présente le nombre de détections correctes de présence d'objets d'intérêt;

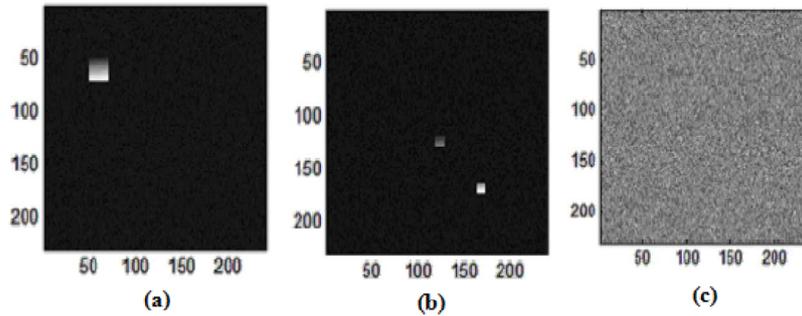


Figure 3.23: Exemples d'images de synthèse contenant différents pourcentages d'occupation par les objets et classées selon la valeur de λ . L'image (a) montre une forte probabilité d'occupation par des objets ($\lambda = 2,203$), l'image (b) montre une probabilité moyenne de présence d'objets ($\lambda = 1,698$) et l'image (c) présente une probabilité proche de zéro de présence d'objet. ($\lambda = 0,674$).

- VDA : présente le nombre de détections correctes d'absence d'objets d'intérêt;
- FAP : présente le nombre de fausses détections de présence d'objets d'intérêt;
- FAA : présente le nombre de fausses détections d'absence d'objets d'intérêt.

	Vrai Présence	Vrai Absence
Présence détectée	VDP	FAP
Absence détectée	FAA	VDA

Tableau 3.7: Matrice de confusion pour la présence/absence des objets d'intérêt.

En appliquant cette matrice sur notre échantillon d'images de synthèse pour le cas où $\alpha = 0,05$, on obtient la matrice de confusion présentée dans le tableau 3.8.

	Vrai Présence	Vrai Absence
Présence détectée	4525	375
Absence détectée	8	3057

Tableau 3.8: Matrice de confusion pour le cas de $\alpha = 0,05$ appliquée sur la base de données synthétisée.

A partir de la matrice de confusion, on peut définir deux quantités : le taux de détection des objets dans l'image et le taux de fausse alarme.

- Le taux de détection des événements rares est la proportion des cas de présences correctes des événements rares ;
 $Taux\ de\ detection = VDP / (VDP + FAP)$
- Le taux de fausses alarmes est la proportion des cas de fausses détections de présence des événements rares :
 $Taux\ de\ fausses\ alarmes = FAA / (VDA + FAA)$

- La proportion du nombre de prévisions correctes donne la précision de notre algorithme définie comme suit :

$$Precision = (VDP + VDA)/(VDA + VDP + FAP + FAA)$$

Pour une mesure quantitative des performances, nous calculons la courbe COR (Caractéristique Opérationnelle de Réception) [MDK⁺98], représentant l'évolution de la probabilité de détection en fonction du taux de fausse alarme. La méthode proposée est alors évaluée au moyen de la courbe COR sur l'ensemble des données de synthèse pour des différentes valeurs de α .

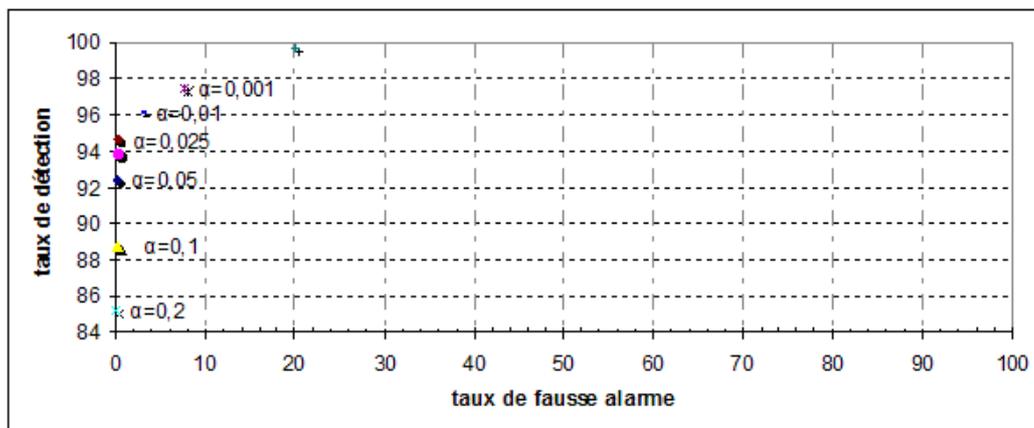


Figure 3.24: Courbe COR : taux de détection en fonction du taux de fausse alarme pour différentes valeurs de α .

La figure 3.24 représente la courbe COR obtenue pour différentes valeurs α . Il apparaît ainsi que la meilleure classification est obtenue pour $\alpha = 0.025$. Pour cette valeur, nous obtenons un taux de détection = 94,95%, un taux de fausses alarmes = 0,33% et la précision de notre algorithme = 96,54%. La valeur de α correspond à une valeur moyenne de $\lambda = 0,88$ qu'on peut désormais utiliser comme facteur de classification dans la base des données de synthèse pour discriminer les images susceptibles de contenir des objets d'intérêt.

3.9 Conclusions

La segmentation d'images est un domaine vaste où l'on retrouve de très nombreuses approches. Ce chapitre dresse brièvement un état de l'art des principales méthodes de segmentation. Chacune possède ses avantages et ses inconvénients.

Dans ce chapitre, nous avons présenté une nouvelle approche pratique pour faire face à la détection des objets d'intérêt en appliquant l'entropie de Shannon. Les différents résultats sont testés sur un ensemble d'images sonar. Les objets sont alors détectés par leurs échos. Cependant, la méthode proposée est totalement indépendante du type de l'objet. L'algorithme proposé peut être appliqué à différents domaines

et reste approprié lorsque les objets intéressants sont enfouis (cas des images sonars).

Notre approche de détection est convertie dans un deuxième temps en une carte de probabilité pour identifier les zones de faible, intermédiaire ou forte probabilité de présence des objets d'intérêt. Étant donné qu'il n'existe pas de méthode universelle pour évaluer les résultats de la segmentation et que sa performance est fonction des résultats obtenus ultérieurement, nous constatons que les résultats obtenus sont encourageants.

En effet, ce résultat est prometteur pour la suite de la procédure de détection puisque seules les images qui contiennent des objets d'intérêt seront traitées.

Caractérisation et détection des objets rares

Sommaire

4.1	Introduction	89
4.2	Caractérisation et classification des objets marquants	89
4.2.1	Méthodes existantes	89
4.2.2	Les différents mécanismes d'apprentissage	94
4.3	Notre approche de détection des objets marquants	96
4.3.1	Caractérisation des objets	96
4.3.2	Classification non supervisée	101
4.3.3	Combinaison des classifieurs	104
4.3.4	Tests et évaluation des résultats	106
4.4	Détection des objets rares : application de la saillance visuelle	110
4.4.1	Rareté et saillance visuelle	110
4.4.2	Carte de saillance	111
4.4.3	Techniques de détection de la saillance dans le domaine transformé	113
4.5	Localisation finale des objets rares	114
4.5.1	Algorithme implémenté	114
4.5.2	Tests et résultats	115
4.6	Conclusions	117

4.1 Introduction

Dans le chapitre précédent, nous avons développé une méthode de segmentation pour détecter les objets d'intérêt. Comme nous l'avons mentionné dans ce chapitre, l'approche de segmentation constitue une étape primordiale pour la suite du processus de détection.

Dans le présent travail, nous utilisons les résultats de la segmentation pour développer les étapes ultérieures de la détection. La première étape consiste à détecter les objets marquants à partir de la classe "objet". A titre de rappel, nous appelons un objet marquant tout objet qui s'éloigne de près ou de loin des objets habituels.

D'une manière plus simple, les objets marquants possèdent certaines propriétés qui les différencient des objets habituels. La localisation des objets marquants nous permet de localiser éventuellement les objets rares. Notre objectif est la détection des objets qui s'écartent significativement de la majorité des autres. Nous proposons donc un algorithme de détection automatique des objets marquants qui ne nécessite ni connaissance *a priori* sur la nature des objets ni une intervention extérieure. L'approche proposée se base sur une étape de caractérisation des objets. Considérant la contrainte de généralité de notre travail, nous désignons une caractérisation particulière des objets. Nous supposons que les objets sont préalablement séparés par une segmentation. Nous procédons ensuite à choisir un type de mécanisme d'apprentissage et à grouper les objets en utilisant différents classificateurs.

Nous distinguons dans la base de données trois types d'objets : objet habituel, objet marquant et objet rare. Dans la deuxième étape de détection, nous proposons donc de discerner la classe des objets rares. Pour atteindre cet objectif, nous avons eu recours aux méthodes de détection de la saillance. Nous détaillerons également l'algorithme de détection des objets saillants que nous avons développé.

4.2 Caractérisation et classification des objets marquants

La représentation des objets est une étape importante dans la phase de reconnaissance des objets. Certains articles, thèses et travaux de recherche se sont intéressés au problème de la caractérisation et classification des objets atypiques. Nous présenterons donc les travaux que nous jugeons intéressants pour notre étude bibliographique.

4.2.1 Méthodes existantes

4.2.1.1 Méthode de F. Cai *et al.*

Fei Cai, dans son travail [CCJ11] s'est intéressé à la détection des objets manufacturés. Ces objets sont considérés comme des événements rares et font l'objet d'une extraction. Les caractéristiques d'intérêt dans ce travail sont : le contraste, les lignes de bords et les angles.

La méthode de détection des objets manufacturés est basée sur l'extraction de la texture et les caractéristiques géométriques de la structure.

Pour détecter les objets rares, F. Cai considère que l'apparition soudaine des objets

présente une anomalie dans la scène. L'algorithme proposé est donc basé sur le calcul de la fréquence d'apparition des objets. Celle-ci devrait être inférieure à la fréquence d'apparition du fond dans la base d'images. La détection finale des objets manufacturés se base sur l'hypothèse que les objets manufacturés possèdent plus de lignes de bords et d'angles que les objets créés par la nature.

L'algorithme de détection des objets manufacturés se résume dans les étapes suivantes :

- Mesure des contrastes de l'image initiale et application des filtres pour améliorer le résultat (étape de prétraitement) ;
- Choix approprié de la fenêtre de calcul ;
- Extraction des caractéristiques géométriques dans chaque fenêtre : bords, lignes et angles ;
- Classification de chaque zone en utilisant l'algorithme des *c*-moyens flous (FCM). L'algorithme FCM sera utilisé détaillé ultérieurement dans notre approche de classification.

La procédure de détection est réalisée dans deux étapes consécutives:

1. Détection primaire de position : cette étape est le résultat du calcul du contraste et de la luminance dans chaque fenêtre de calcul. Le calcul de l'ensemble des indices de contraste ($F_{contrast}$) pour toute l'image permet de tracer une courbe de contraste. Les zones contenant les objets manufacturés sont situées dans les pics de cette courbe ;
2. Détection finale et marquage : dans cette étape, les lignes et les angles sont détectés pour distinguer les objets manufacturés.

4.2.1.2 Méthode de Sanjiv Kumar

Kumar, dans son travail [KH03b], propose une approche générique pour détecter les structures manufacturées dans une image naturelle. Il utilise un vecteur des caractéristiques multi échelles pour détecter les dépendances locales entre les données. Les objets manufacturés sont caractérisés par des propriétés statistiques définies sur plusieurs échelles.

Le vecteur multi-échelle de chaque bloc contient un ensemble de caractéristiques intra échelle et inter échelle. Pour définir les caractéristiques intra-échelles, l'auteur se base sur l'hypothèse que les objets manufacturés sont caractérisés par des arêtes et des bords linéaires. Le vecteur caractérisation intra-échelle est défini en suivant les étapes suivantes :

- Calcul de l'amplitude du gradient et de l'orientation dans chaque bloc ;
- Construction de l'histogramme de gradient et de l'orientation pour chaque bloc ;

- Lissage de l'histogramme en utilisant la technique de Kernel¹ ;
- Lorsque le bloc de l'image (la fenêtre de calcul) présente une région texturée, celle-ci est identifiée par une distribution uniforme des pics de l'histogramme. Cependant, si l'histogramme présente des pics très significants par rapport aux autres pics alors, le bloc visité présente des structures linéaires intégrées dans le background ;
- La moyenne des pics est utilisée comme indicateur sur la linéarité de la structure du bloc ;
- Calcul de deux moments μ_0 et μ_1 pour chaque échelle (2 caractéristiques intra-échelle du bloc) ;
- La caractéristique de l'orientation est calculée pour chaque bloc et dans chaque niveau en considérant les deux plus importants pics de l'histogramme.

Pour définir les caractéristiques inter-échelle, l'auteur mesure la continuité des lignes et des angles dans les différents niveaux en se basant sur la caractéristique orientation.

Dans ce travail, l'auteur utilise l'apprentissage des données pour extraire les caractéristiques génériques des blocs de l'image. L'étape de classification est réalisée suite à l'étude de la distribution statistique des caractéristiques définies dans la phase d'apprentissage. La contribution de l'auteur réside dans l'utilisation de la modélisation de probabilité *a priori* en appliquant la technique des champs multi-échelles (*multiscale random field : MSRF*)². L'approche remplace le modèle MRF par un nouveau modèle multi échelle MSRF et remplace l'estimateur du Maximum a posteriori MAP par l'estimateur séquentiel SMAP.³

4.2.1.3 Méthode de Y.Caron *et al.*

Caron propose dans son travail [CMV02] une nouvelle approche de détection des objets artificiels dans un environnement naturel. La méthode de détection se base sur l'étude de la distribution statistique des modèles de texture dans l'image.

La distribution des modèles est calculée en utilisant la loi de Zipf.⁴ L'image est tout d'abord divisée en sous trames. La comparaison entre les courbes

¹Une technique d'estimation de la fonction de régression ou de la fonction de densité de probabilité d'une série de nombres aléatoires.

²Technique de modélisation plus récente que les champs de Markov (*Markov Random Field, MRF*). Cette technique est le plus souvent appliquée dans la segmentation sémantique des images. Le modèle MSRF permet une décomposition hiérarchique du niveau le plus grossier au niveau le plus fin.

³L'estimateur du "maximum a posteriori séquentiel" (SMAP), proposé par Bouman et Shapiro, est une nouvelle version du MAP adaptée aux problèmes d'estimations dans le cadre des champs multi-échelles "multiscale random field" (MSRF)

⁴La loi de Zipf est une observation empirique qui étudie la répartition statistique des fréquences des mots dans un langage. Cette loi à été découverte par le linguiste américain George Zipf en 1949.

de la distribution de Zipf pour chaque sous-trame permet de déduire la sous-trame contenant un objet. L'idée de base pour la détection d'un objet artificiel se résume dans l'hypothèse suivante : la présence d'un objet artificiel modifierait la distribution de la fréquence d'occurrence des modèles calculés par la loi de Zipf dans les régions contenant ces objets. L'application de la méthode générale de codage de rang sur l'ensemble de deux images, l'une artificielle et l'autre naturelle, permet de déduire les caractéristiques de la courbe de Zipf pour chaque classe des objets (naturel / artificiel). Pour le cas d'un objet naturel, la courbe est approximativement linéaire alors que dans le cas de l'objet artificiel, la courbe présente un pic et une pente plus aigüe.

Ces dernières caractéristiques sont utilisées pour détecter la position des objets artificiels. La méthode proposée est totalement indépendante de la forme de l'objet. Cependant, les résultats de détection présentent de fausses détections lorsque l'image présente des objets naturels mais uniformes.

4.2.1.4 Méthode de G.Cao *et al.*

Le travail présenté dans [CYZ05a] propose une méthode de détection des objets manufacturés dans une image aérienne. L'auteur dans ce travail utilise la métrique de l'erreur fractale⁵ comme caractéristique de détection des objets manufacturés.

L'idée de détection des objets manufacturés est basée sur l'hypothèse suivante : les objets naturels s'adaptent bien au modèle de mouvement brownien fractionnaire (fBm)⁶ alors que les objets manufacturés ne s'accordent pas avec ce modèle.

Dans ce travail, l'approche de détection des objets manufacturés est réalisée en deux étapes. Dans la première étape, l'erreur fractale est calculée pour définir la première caractéristique de l'objet. Dans la deuxième étape, les caractéristiques de la texture de bord sont extraites pour améliorer les résultats de détection basés seulement sur l'erreur fractale. L'auteur utilise l'approche de transformée en cosinus discrète, DCT (*Discrete Cosine Transform*) pour extraire les bords de la texture.

Les objets naturels produisent une erreur fractale très faible alors que les objets manufacturés produisent une erreur fractale très importante.

Zipf, a montré qu'en classant la fréquence d'apparition des mots d'un texte par ordre décroissant, on obtient une fréquence d'utilisation d'un mot inversement proportionnelle à son rang. La loi de Zipf peut être exprimée de par la formule suivante: $F(N) = F(1)/N$ avec $F(1)$ et $F(N)$ respectivement la fréquence du mot de rang 1 et N.

La loi de Zipf a été ensuite reformulée par Jean-Baptiste Estoup et Benoît Mandelbrot.

⁵La dimension fractale contient l'information sur la structure géométrique de l'objet. Elle est considérée comme une caractéristique importante des objets fractals puisqu'elle permet de mesurer le degré de leur irrégularité. Le calcul de l'erreur fractale permet d'évaluer le degré d'appartenance d'un pixel à une structure fractale donnée.

⁶Le mouvement brownien fractionnaire (en anglais *fractional Brownian motion*) de paramètre H tel que $0 < H < 1$ est un modèle non stationnaire de signaux fractals stochastiques. Le paramètre H permet de quantifier la rugosité d'une image. Il permet également de caractériser les textures et d'analyser les surfaces dans une image. Le modèle est utilisé pour modéliser des signaux issus de phénomènes physiques tels que des bruits, des séries économiques, ...

4.2.1.5 Méthode de Perry et Guan

Dans leur travail [PG01], Perry et Guan ont développé une méthode de détection des petits objets manufacturés dans une base des images sonars. L'approche de détection se base sur une étape de caractérisation des objets et l'utilisation d'un système de réseau de neurones. Les caractéristiques des objets sont extraites à partir de la base d'apprentissage puis exploitées pour former le réseau de neurones permettant la détection des objets manufacturés.

Dans une première étape, l'approche de détection fait appel à une méthode de pré-traitement des données, puis les différents objets de l'image sont séparés par une segmentation locale basée sur le calcul des voisins. Pour construire le vecteur caractéristique des objets, l'auteur utilise les attributs de la forme, l'intensité, les différents moments statistiques et les caractéristiques du second ordre de l'histogramme.

L'algorithme proposé permet de réduire le nombre des caractéristiques en utilisant le détecteur réseaux de neurones de régression généralisée (*General Regression Neural Network* (GRNN)). La contribution de chacune des caractéristiques est testée par l'intermédiaire d'une de deux approches SFS ou SBS. Ces deux approches permettent de réaliser un traitement séquentiel d'ajout (ou de suppression) de caractéristiques et de comparaison avec les performances de détecteur.

Finalement, les caractéristiques les plus importantes sont sélectionnées en utilisant le réseau neuronal de type MLP⁷.

Le calcul de performance de détecteur est réalisé en se basant sur le calcul de l'erreur quadratique moyenne entre la réponse du détecteur à un exemple test et la réponse réelle.

4.2.1.6 Méthode de A.Soto *et al.*

Soto *et al.* dans le travail [SCZ05] présentent une application d'une technique d'extraction des connaissances permettant de détecter les événements inhabituels dans un ensemble des données astronomiques. Le modèle proposé est une combinaison de réseau bayésien et de l'approche gaussienne GMMs traités avec l'algorithme EM.

L'idée de la détection des événements rares est basée sur la réalisation des modèles des objets naturels (étoiles, galaxies...) dans l'image astronomique puis de comparer les distances entre les objets rencontrés et les modèles réalisés.

L'observation d'une très grande base des données d'images de ciel permet de réaliser un modèle probabiliste des objets de la base des données. Le modèle probabiliste considère la distribution de probabilité conjointe (JPD) des attributs des objets dans la base de données. L'utilisation d'un réseau bayésien permet de mettre en relief l'indépendance conditionnelle entre les différents attributs définis dans le travail.

⁷Un réseau neuronal est une association d'objets élémentaires présentant des neurones formels. Les réseaux de type MLP (*Multi-Layer Perceptron*) ou réseau de neurones multi-couches réalisent une combinaison linéaire des entrées. Le perception multicouche est un réseau organisé en couches. Une couche est un groupe de neurones n'ayant pas de connexion entre eux. Chaque couche réalise une transformation vectorielle : elle reçoit un vecteur d'entrée et le transforme en vecteur de sortie.

4.2.1.7 Méthode de Yang *et al.*

Le but du travail présenté dans [YQY09] est de développer une méthode rapide et automatique pour la détection des objets manufacturés dans les images radars.

La méthode de détection présente une approche générique basée sur les machines à vecteur de support (SVM)⁸. La construction du système générique se base sur l'extraction des différentes caractéristiques des objets manufacturés (extraction de contour, descripteurs géométriques et des descripteurs de niveau de gris) pour améliorer les résultats de détection. Le travail réalisé permet d'étudier quatre types d'objets manufacturés : bords, ronds-points, rivières et ports de pêche.

L'extraction des attributs des objets manufacturés est réalisée en deux étapes : d'abord détection de contour (application de la méthode de Tupin) puis extraction des caractéristiques de l'objet (niveau de gris et attributs géométriques). Les attributs de niveau de gris sont obtenus à partir de l'image initiale et sont calculés en utilisant les descripteurs statistiques de luminance : Skewness et Kurtosis. Les attributs géométriques sont calculés sur les zones détectées par l'approche de Tupin en utilisant les invariants de Hu (famille de 7 invariants) et la densité de bord.

L'étape de la classification est réalisée par la LS-SVM (*Least-Squares Support Vector Machines*) en utilisant la fonction de base radiale (RBF).

4.2.2 Les différents mécanismes d'apprentissage

Les approches de détection automatique des objets saillants sont largement appliquées dans différents domaines tels que le recalage, l'indexation, la recherche, la compression des images et ainsi de suite. Quand on dispose des connaissances *a priori* sur les objets recherchés, l'approche de détection est caractérisée de "spécifique" et elle présente le type de détection le plus simple à implémenter.

Cependant, nous proposons de développer une approche générique de détection des objets atypiques où aucune connaissance n'est fournie. L'algorithme détecte les objets marquants qui s'écartent significativement des objets normes qu'on appelle objets habituels. Ce type de détection sous-tend l'exploitation d'un mécanisme d'apprentissage pour la classification des objets. Ce qui pose la question de la mise en place d'un apprentissage supervisé ou semi supervisé ou non supervisé.

Dans la suite de cette section, nous expliquerons brièvement chacune des trois techniques d'apprentissage. Nous présenterons également les travaux les plus connus de détection des objets atypiques dans chaque mécanisme.

4.2.2.1 Apprentissage supervisé

Les techniques d'apprentissage supervisé visent à apprendre des modèles complexes à partir d'un ensemble de données étiquetées. Considérant une base d'apprentissage,

⁸Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais *Support Vector Machine*, SVM) forment un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination et de régression. Les SVM sont définies comme une généralisation des classifieurs linéaires. En se basant sur les données d'apprentissage, les SVM permettent de créer une fonction de décision pour la classification.

toutes les classes possibles sont connues et tous les objets sont fournis avec leurs étiquettes. A partir de cette base, les objets sont caractérisés par des attributs qualitatifs ou quantitatifs. L'objectif principal de la classification est de définir des règles permettant d'associer les données étiquetées à leur classe.

Les principaux algorithmes de classification supervisée actuellement utilisés sont les réseaux de neurones artificiels, la technique des machines à vecteurs de supports (SVM) et la technique de *boosting*. Compte tenu des scènes simples et statiques, ces approches de classification offrent des solutions efficaces pour la modélisation et la détection des événements inhabituels.

Dans la littérature, plusieurs travaux de recherches se sont intéressés à la détection des événements inhabituels par application des méthodes d'apprentissage supervisé. Par exemple, Sacchi *et al.* [SRGF01] ont appliqué l'apprentissage pour distinguer entre les deux comportements normaux et inhabituels des actes de vandalisme. Zhang *et al.* [ZDGP06] ont reconnu les interactions inter-groupes parmi un nombre limité de participants dans une salle de réunion à l'aide des modèles de Markov cachés (CMM). De même, Cupillard *et al.* [CBT02] a reconnu les interactions inter-groupe avec un nombre fixe de participants. D'une manière différente, Morris et Hogg [MH00] ont détecté les trajectoires atypiques par apprentissage d'un modèle statistique avec des trajectoires à la fois normales et atypiques.

Néanmoins, dans le cas supervisé, le manque de données d'apprentissage ou la présence de données incertaines peut aboutir à une mauvaise classification.

4.2.2.2 Apprentissage non supervisé : le *clustering*

Dans le cas d'apprentissage non supervisé, toutes les données de la base sont non étiquetées et les classes et leurs nombres sont inconnus. Ce type d'apprentissage permet d'identifier et de regrouper les données homogènes en différentes classes ou clusters en fonction d'une certaine mesure de similarité.

D'une manière générale, la similarité entre les objets est calculée à l'aide d'une fonction estimant la distance entre les objets. Le choix de cette mesure influe profondément sur les résultats de la classification puisque le *clustering* l'utilise pour étudier à la fois la distance entre les objets appartenant au même groupe et la distance entre les clusters.

Dans la littérature, plusieurs techniques de *clustering* ont été développées. Fraley et Raftery [FR98] ont suggéré de diviser les méthodes de *clustering* en deux groupes principaux : les méthodes hiérarchiques et les méthodes de partitionnement.

Les algorithmes hiérarchiques visent à créer une décomposition hiérarchique des objets sous forme d'arbre composés de clusters. Les algorithmes de *clustering* par partitionnement cherchent à trouver la meilleure partition des données d'une façon itérative en minimisant un critère donné (le plus souvent ce critère est l'erreur quadratique).

Dans les travaux de recherche s'intéressant à la détection des objets atypiques et utilisant le *clustering*, une stratégie commune consiste à regrouper l'ensemble des données en deux groupes et étiqueter les petits groupes comme inhabituels. Par exemple, Zhong *et al.* [ZSV04] ont effectué une classification des segments de la

vidéo en deux groupes puis ils identifient les groupes isolés comme des événements inhabituels. Lee *et al.* [LHWH06] ont utilisé une technique de *clustering* hiérarchique pour séparer les comportements inhabituels des comportements normaux en utilisant une mesure de distance. De même Hamid *et al.* [HJB⁺05] ont utilisé une méthode théorique et graphique de *clustering* (*graph theoretic clustering*) pour détecter les événements normaux et les événements anormaux. L'anomalie est déterminée par un simple calcul de la similitude entre un événement donné et tous les événements dans les clusters existants.

4.2.2.3 Apprentissage semi-supervisé

Ce type d'apprentissage est généralement utilisé lorsqu'un grand nombre des données est disponible dans la base mais seules quelques données sont étiquetées.

Dans le cas de l'apprentissage semi-supervisé, un modèle est proposé pour représenter l'appartenance des objets à différentes classes prédéfinies et les exemples non étiquetés sont utilisés pour apporter l'information. Généralement, ce modèle est initialisé avec un petit nombre de données étiquetées et un grand nombre des données non étiquetées. Les données non étiquetées sont utilisées pour entraîner le classifieur séquentiellement.

La stratégie d'apprentissage paraît ainsi comme une solution intermédiaire entre les deux autres types d'apprentissage. Cependant, une difficulté majeure apparaît lorsque seules certaines données sont étiquetées. Ce problème peut aboutir, dans certains cas, à la propagation des connaissances biaisées acquises à partir des données non étiquetées.

4.3 Notre approche de détection des objets marquants

Le choix de la méthode de classification est lié à plusieurs facteurs parmi lesquels on peut citer la présence des étiquettes dans les données d'apprentissage. Cependant, indépendamment, du mécanisme d'apprentissage, le développement d'une méthode efficace de détection des objets qui s'écartent largement des objets habituels exige une caractérisation performante des objets. Dans la suite de ce chapitre, nous présenterons les données pertinentes que nous avons recueillies pour faire l'apprentissage des différents modèles. Compte tenu de la contrainte d'absence de contexte, nous procédons ensuite à la classification des objets en utilisant différentes approches de *clustering*. Notre idée pour améliorer les résultats de la classification en utilisant la même description de l'objet, est d'adopter une méthode de fusion des classifieurs⁹.

4.3.1 Caractérisation des objets

Notre but dans cette étape est le choix des caractéristiques appropriées pour un système générique. Un ensemble de mesures des caractéristiques locales adéquates

⁹Une étude sur la fusion de données est détaillée dans l'annexe B

pour la description de chaque objet est alors nécessaire. Idéalement, la caractérisation de l'objet vise à fournir une discrimination entre les éléments qui constituent la base des images indépendamment de la nature des objets.

Pour pallier la contrainte de la grande diversité des possibilités d'objets étudiés, nous proposons une caractérisation sémantique. Cette caractérisation doit être non seulement invariante aux transformations géométriques, mais aussi indépendante de la forme des objets et ne repose sur aucune connaissance *a priori* sur la nature des objets à détecter.

Notre idée est d'étudier la dispersion de l'objet du point de vue à la fois de la forme et de la caractérisation sémantique. Pour atteindre ces objectifs, le vecteur caractéristique de l'objet est défini en combinant les attributs géométriques et les attributs évaluant la ressemblance d'un échantillon donné à ses voisins dans l'image (ces attributs sont désormais nommés "attributs sémantiques"). Les étapes de caractérisation d'un objet dans la base d'apprentissage sont résumées sur le diagramme de la figure 4.1

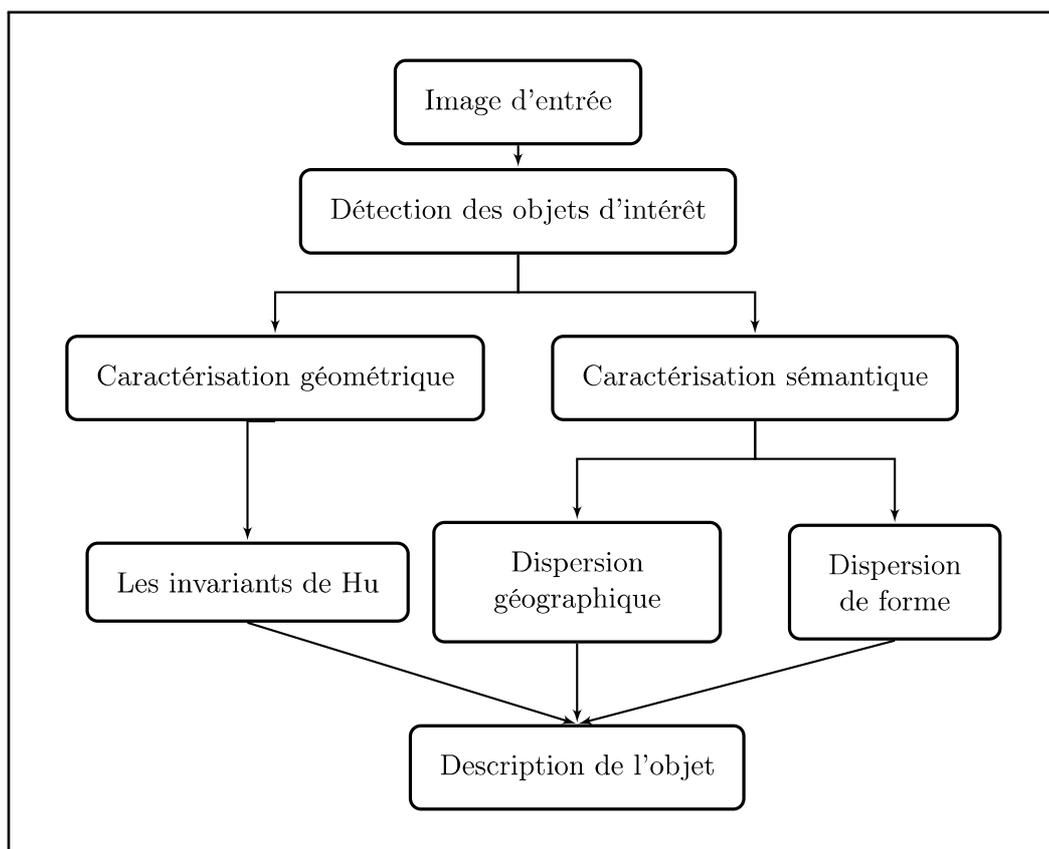


Figure 4.1: Diagramme de description des objets.

4.3.1.1 Attributs géométriques

Les invariants géométriques sont utilisés comme des descripteurs géométriques calculés à partir des objets extraits. Un enjeu essentiel de la reconnaissance des objets est sa définition indépendamment de leur position, leur échelle et leur orientation. La caractéristique de la forme est une propriété fondamentale de l'objet; une description efficace de la forme est donc une clé pour la reconnaissance des objets.

D'autre part, le moment statistique est un indicateur de dispersion largement utilisé pour la reconnaissance de la forme. L'idée d'utiliser des moments statistiques pour la reconnaissance de la forme est d'abord introduite par Hu [MK62]. Hu a défini une famille de sept invariants en utilisant les moments centraux normalisés. Cette famille est définie comme suit :

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p \cdot (y - \bar{y})^q f(x, y) \quad p, q = 0, 1, 2, \dots \quad (4.1)$$

avec

- x et y les coordonnées de l'image $f(x, y)$
- $\bar{x} = \frac{m_{10}}{m_{00}}$ et $\bar{y} = \frac{m_{01}}{m_{00}}$
- $m_{00} = AireImage/Volume$, $m_{01} = Somme\ sur\ x$, $m_{10} = Somme\ sur\ y$.

Typiquement, les invariants de Hu sont définis en utilisant une combinaison des moments centraux d'ordre trois décrits dans [MK62, AMP84] comme suit :

$$\begin{aligned} I_1 &= \eta_{20} + \eta_{02} \\ I_2 &= (\eta_{20} - \eta_{02})^2 + 4 \eta_{11}^2 \\ I_3 &= (\eta_{30} - 3 \eta_{12})^2 + (3 \eta_{21} - \eta_{03})^2 \\ I_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\ I_5 &= (\eta_{30} - 3 \eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03}) \\ &\quad (\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ I_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 + 4\eta_{11}(\eta_{30} + \eta_{12}) + (\eta_{21} + \eta_{03})] \\ I_7 &= (3 \eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (\eta_{30} - 3 \eta_{12})(\eta_{21} + \eta_{03}) \\ &\quad [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned}$$

Considérant leur propriété d'invariance au changement de rotation, de translation et d'échelle, nous définissons la première partie du vecteur des caractéristiques en calculant les sept invariants de Hu.

4.3.1.2 Raisonnement hypothétique : caractérisation sémantique des objets

La reconnaissance des objets d'intérêt dans un ensemble d'images est l'un des problèmes les plus complexes en vision par ordinateur, en particulier lorsque la caractérisation de l'objet nécessite des connaissances externes. Toutefois, l'être humain

possède une grande capacité à interpréter l'image car il a une connaissance *a priori* sur l'environnement étudié et son contenu.

Généralement, le fossé sémantique est défini comme l'écart entre le niveau bas de la représentation d'une image et l'interprétation de haut niveau associée au raisonnement humain (Une étude du fossé sémantique dans le cadre de traitement d'images est réalisée dans le chapitre 1). En tenant compte de ces définitions, nous utilisons la sémantique pour caractériser un objet rare. Cette caractérisation devrait être indépendante du champs d'application et ne nécessite pas une intervention de l'utilisateur.

Pour définir les attributs sémantiques, nous incorporons le raisonnement hypothétique [Ish92]. Cela signifie que nous définissons les relations entre les différents objets extraits d'une image en intégrant une connaissance générale. Les mesures qui en résultent sont utilisées pour compléter la deuxième partie du vecteur de caractéristiques.

Pour décrire les concepts liés à la présence de l'objet rare dans un ensemble donné d'images, nous définissons les ontologies suivantes :

- Un échantillon des images est composé obligatoirement d'un certain nombre d'objets similaires les uns aux autres et d'un nombre plus petit d'objets différents ;
- Les objets marquants possèdent certaines propriétés qui sont différentes des objets classiques ;
- Un objet marquant est généralement isolé ou loin des autres objets présents dans l'image ;
- Les objets ordinaires sont plus fréquents dans l'image et sont souvent rassemblés.

En se basant sur ces constats, deux mesures sont proposées pour calculer le degré de dispersion de l'objet du point de vue sémantique.

En utilisant une fenêtre de calcul, la première mesure sémantique (appelée Attribut Sémantique 1 (AS1)) évalue le critère de distance en attribuant une valeur pondérée pour chaque objet rencontré dans la fenêtre.

La taille de la fenêtre glissante pourra être fixée en considérant la taille approximative du plus petit objet qui pourrait être rencontré dans l'image segmentée, comme on peut la fixer d'une façon arbitraire.

Nous utilisons la distance euclidienne pour évaluer la dispersion géométrique de l'objet par rapport à ses voisins. Nous calculons cette quantité à l'aide de l'expression suivante :

$$AS1_k = \frac{\sum_i^{nbk} \sqrt{(x_k - x_i)^2 (y_k - y_i)^2}}{9 \cdot \max(V_k)} \quad (4.2)$$

avec

$$\max(V_k) = \max_{i=1..nbk} \left(\sum_{j=1}^{nbk} \sqrt{(x_i - x_j)^2 (y_i - y_j)^2} \right) \quad (4.3)$$

(x_k, y_k) sont les coordonnées de barycentre de l'objet k . nbk correspond au nombre des voisins de l'objet dans la fenêtre de calcul.

La deuxième mesure sémantique (appelée Attribut Sémantique 2 (AS2)) évalue la dispersion morphologique liée à l'objet rare. Comme les irrégularités dans la forme ont un fort impact dans la classification des objets, nous proposons d'utiliser les indices de forme pour étudier la dispersion géométrique de l'objet.

Considérant que l est la longueur finale du vecteur caractéristique et que μ_k et μ_i sont les indices de forme calculés respectivement pour les objets de centroïdes k et i , la caractérisation de dispersion de forme de l'objet est calculée en utilisant la formule suivante:

$$As2_k = \frac{\sum_i^{nbk} (\mu_k - \mu_i)}{l \cdot \max v_k} \quad (4.4)$$

avec

$$\max(V_k) = \max \left(\sum_{i=1}^{nbk} (\mu_k - \mu_i), k = 1..nbk \right) \quad (4.5)$$

Nous proposons d'appliquer un des indices de forme pour évaluer la circularité de l'objet.

Dans la littérature, la forme de l'objet est définie en utilisant une description basée sur de nombreuses mesures comme la longueur, la largeur, le diamètre du disque équivalent, l'allongement, le facteur de sphéricité, l'indice rondeur /angularité, etc. Les techniques classiques d'analyse de l'image [V.J98] sont basées sur le diamètre équivalent de disque (D), la sphéricité (S), l'allongement (τ) et l'indice de circularité (R). Ces mesures sont le plus souvent définies respectivement par les expressions suivantes :

$$D = \sqrt{\frac{4 \cdot A}{\pi}} \quad (4.6)$$

$$S = \frac{6 \cdot V}{D_0 \cdot A} \quad (4.7)$$

$$\tau = \frac{L_{max}}{L_{min}} \quad (4.8)$$

$$R = \frac{4 \cdot \pi \cdot A}{p^2} \quad (4.9)$$

où

- A = l'air de l'objet, V = le volume de l'objet et P = le périmètre de l'objet ;
- D_0 est le diamètre de la sphère ayant le même volume $\frac{\pi \cdot D_0^3}{6}$;
- L_{max} la longueur de l'axe principale et L_{min} longueur de l'axe secondaire.

Pour chaque objet sélectionné, les caractéristiques géométriques et sémantiques sont combinées pour définir le vecteur des caractéristiques. Dans notre travail, nous utilisons une valeur de l égale à 9 en considérant les 7 attributs géométriques et les 2 attributs sémantiques.

Nous avons donc procédé de façon à pondérer chaque attribut géométrique par un

indice qui mesure le degré de sa dispersion selon la position géographique et le facteur de forme. Chaque objet est dans ce cas, caractérisé par une mesure qui calcule le taux de sa différence par rapport à la fois des objets existants dans l'image et ses voisins adjacents. La figure 4.2 présente toutes les mesures calculées dans le cadre simplifié d'une image contenant trois objets différents (un objet rare et deux objets habituels).

Dans le chapitre suivant, nous détaillerons cette démarche que nous débuterons par une étude bibliographique.

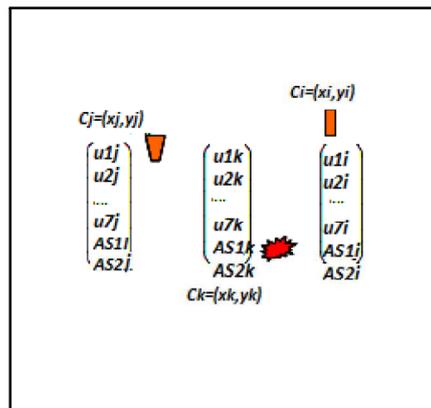


Figure 4.2: Les caractéristiques sémantiques et géométriques calculées pour un échantillon d'objets de classes différentes.

4.3.2 Classification non supervisée

À ce stade de travail, nous proposons d'appliquer une technique de classification fiable pour séparer les deux classes : objets marquants et objets habituels. Basé sur la description donnée aux objets, le système de classification accordera une étiquette à chaque entrée en fonction de son appartenance à l'une des deux classes.

D'une manière générale, il est toujours plus facile de collecter les exemples non étiquetés que les objets étiquetés. Dans le cas des objets marquants ou inhabituels, nécessitant une annotation exhaustive des experts humains, il est souvent difficile d'obtenir une base étiquetée. Nous proposons donc d'utiliser une méthode de classification non supervisée.

Dans la pratique, une partie des données est utilisée pour l'apprentissage et la partie complémentaire sera utilisée pour les tests. Nous choisissons d'appliquer trois différentes approches de classification : le *Kmeans*, l'algorithme de K-means flou (FCM) et l'algorithme de modèle de mélange gaussien (en anglais *Gaussian Mixture Model*(GMM)).

4.3.2.1 Algorithme de K moyennes (*Kmeans*)

Grâce à son efficacité et sa rapidité, l'algorithme *Kmeans* est très souvent utilisé pour le partitionnement hiérarchique des données. La méthode de *Kmeans* permet de partitionner n observations dans k ensembles en minimisant la quantité :

$$\sum_{r=1}^k \sum_{x_i \in C_r} (x_i - g_r)^2 \quad (4.10)$$

avec

C_r la classe numéro r et g_r son centre. D'une manière générale, l'algorithme de *Kmeans* est le suivant:

Algorithm 1 *Kmeans*

- 1: **Entrées:**
 - 2: ensemble de n observations.
 - 3: nombre maximum des groupes souhaités noté k .
 - 4: **Début :**
 - 5: Choisir k observations centres des classes initiales ;
 - 6: Affecter chaque observation au centre le plus proche ;
 - 7: Réévaluer le centre de chacune de ces k classes;
 - 8: Répéter les étapes (6) et (7) jusqu'à stabilité des centres.
 - 9: **Fin.**
-

La sortie de cet algorithme est une partition de k groupes C_1, C_2, \dots, C_k . Chaque classe est représentée par un vecteur moyen de tous ses individus (centre de la classe). Nous appliquons l'algorithme K-means sur l'ensemble des vecteurs caractéristiques des objets d'apprentissage. Chacune des deux classes (habituelle/marquante) est au final présentée par un vecteur moyen de tous les individus qui lui appartiennent.

4.3.2.2 Algorithme de Kmeans flou (FCM)

L'algorithme de FCM (en anglais *Fuzzy C-Means*) a été développé par Dunn en 1973 [Dun73] et amélioré par Bezdek [Bez81] en 1981. Il est basé sur la minimisation de la fonction objective suivante :

$$J_m = \sum_{i=1}^N \sum_{j=1}^C \mu_{ij}^m \|x_i - C_j\|^2, m \geq 1; \quad (4.11)$$

Pour un partitionnement flou des données, l'algorithme FCM est le plus connu. Le principe de FCM est similaire à l'algorithme de *K-means* et, de plus, il introduit le degré d'appartenance dans le critère de convergence à minimiser. L'algorithme FCM introduit à chaque donnée de la base un degré d'appartenance à une classe donnée.

Considérant μ_{ik} le degré d'appartenance du pixel i à la classe k et U est la matrice de partition définie par $U = [\mu_{ik}]$, les étapes de l'algorithme FCM sont décrites comme suit :

Algorithm 2 FCM

1: **Entrées:**

- 2: nombre des groupes souhaité noté par C .
 3: Fixer la valeur de seuil ξ (condition d'arrêt).

4: **Début :**

- 5: Initialiser la matrice de partition $U = [\mu_{i,j}] : U^{(0)}$
 6: Pour chaque itération k , calculer la matrice de partition et les centres des vecteurs $C^k = [c_j]$ suivant les deux équations :

$$1. c_j = \frac{\sum_{i=1}^N \mu_{ij}^m \cdot x_i}{\sum_{i=1}^N \mu_{ij}^m}$$

$$2. \mu_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}$$

- 7: si $\|U^{(k+1)} - U^{(k)}\| < \xi$ alors *stop*, sinon répéter l'étape précédente.

8: **Fin.**

Nous appliquons également cet algorithme de *clustering* sur l'ensemble des données issues de la segmentation (images binaires). La classification de nos objets est réalisée en attribuant à chaque objet la classe la plus probable.

4.3.2.3 Modèle du mélange Gaussien (GMM)

Nous avons également testé une méthode de partitionnement des données basée sur la densité. Nous optons pour le modèle GMM également très appliqué pour la classification non supervisée des données.

Pour les méthodes de *clustering* de type GMM, la fonction de densité de probabilité des données est supposée être une densité de mélange à k composantes.

Le modèle de mélange gaussien permet d'exprimer la distribution des variables aléatoires en les modélisant comme une somme de k gaussiennes. La technique de classification a pour objectif l'estimation des paramètres du modèle de mélange. Il s'agit ici de déterminer la variance, la moyenne et l'amplitude de chaque classe.

Typiquement, la méthode de maximum de vraisemblance est la plus connue pour estimer les paramètres de la distribution de probabilités d'un échantillon donné. De même, l'algorithme Espérance-Maximisation (EM, en anglais *Expectation Maximization*) est le modèle le plus utilisé pour estimer les paramètres d'un modèle de mélange gaussien. L'algorithme de EM utilisé pour la méthode de GMM est le suivant :

Algorithm 3 Algorithme EM appliqué dans la méthode de GMM

1: **Entrées:**2: Ensemble d'observation (X_1, \dots, X_n) .3: Nombre de classes préalablement connu = K .4: Fixer la valeur de seuil ξ (condition d'arrêt)5: **Début :**

6: Initialiser la fonction des paramètres de Vraisemblance :

$$\psi^{(0)} = (\pi_1^{(0)}, \dots, \pi_k^{(0)}, \psi_1^{(0)}, \dots, \psi_k^{(0)}) \text{ avec } \psi_k^{(0)} = (\mu_k^{(0)}, \Sigma_k^{(0)})$$

NB : μ_k et Σ_k sont les moyennes et la matrice de covariance de la classe k .7: Pour chaque itération calculer les deux étapes de l'algorithme *EM* :1. Étape *E* (Estimation): Calculer les probabilités :

$$\tau_{ik} = p(z_i = k | x_i, \psi^{(q)})$$

2. Étape *M* (Maximisation): Mise à jour

$$\psi^{(q+1)} = \operatorname{argmax}_{\psi} Q(\psi, \psi^{(q+1)})$$

$$\Pi_k^{(q+1)} = \frac{\sum_{i=1}^n \tau_{ik}^{(q)}}{n}$$

$$\mu_k^{(q+1)} = \frac{1}{n_k^{(q)}} \sum_{i=1}^n \tau_{ik}^{(q)} x_i$$

$$\Sigma_k^{(q+1)} = \frac{1}{n_k^{(q)}} \sum_{i=1}^n \tau_{ik}^{(q)} (x_i - \mu_k^{(q+1)})(x_i - \mu_k^{(q+1)})^T$$

8: Si $\log \text{ vraisemblance} < \xi$ alors *stop* sinon répéter l'étape précédente.9: **Fin.**

Comme le *clustering* est le groupement des objets en des classes similaires, la mesure de distance est nécessaire pour déterminer la similitude ou la dissemblance entre les objets de la scène. Nous avons choisi de calculer la distance entre les deux objets en utilisant la distance euclidienne et la distance de Manhattan définies respectivement comme suit :

$$Euclid = \sqrt{\sum_{k=1}^l (\alpha_k - \beta_k)^2} \quad (4.12)$$

$$Mandist = \sum_{k=1}^l |\alpha_k - \beta_k| \quad (4.13)$$

où l est le nombre des attributs, α_k et β_k sont respectivement les k^{eme} attributs des objets α et β .

4.3.3 Combinaison des classifieurs

Les différents classifieurs que nous avons utilisés, présentent des caractéristiques variées leurs permettant d'être plus fiables sur un ensemble de données et moins fiables sur un autre. C'est pourquoi on obtient parfois des comportements distincts vis-à-vis du même objet à classifier.

Le but principal de la combinaison des classifieurs est l'augmentation des performances. Cette amélioration dans la performance peut se traduire par plus de fiabilité dans les réponses, moins d'erreurs de classification ou bien les deux à la fois. L'utilisation d'une méthode de combinaison des données peut nous permettre de bénéficier des points forts de chacune des trois méthodes testées. Une décision plus fiable peut être obtenue en combinant les sorties des trois classifieurs.

La phase de combinaison consiste à prendre la décision finale en appliquant des fonctions de combinaison sur les sorties de trois classifieurs utilisés. Le processus de combinaison que nous avons adapté est présenté sur la figure 4.3.

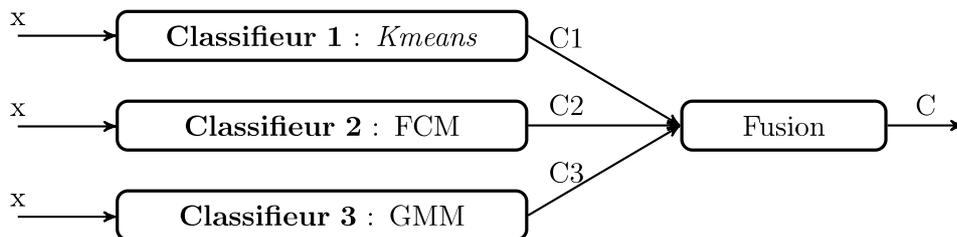


Figure 4.3: Schéma simplifié de la combinaison des sorties de classifieurs.

Pour la suite de notre travail, nous avons utilisé deux méthodes de combinaison : la méthode du vote à majorité et la méthode de la somme pondérée.

4.3.3.1 Méthode du vote majoritaire

Le vote majoritaire est la règle de décision particulièrement la plus simple à mettre en œuvre. Elle ne nécessite pas de connaissance préalable du comportement de chaque classifieur ni un apprentissage des données de la base [LS93].

Certaines études antérieures intéressées par le vote majoritaire simple ont montré que cette méthode est aussi plus efficace que les autres méthodes plus complexes. Un exemple de ces études est réalisé par Franke et Mandler dans [FM92].

Les méthodes du vote majoritaire consistent à faire voter de manière indépendante plusieurs classifieurs et à retenir la réponse majoritaire, correspondant normalement à la meilleure solution.

Dans le cadre de notre travail, nous appliquons le vote majoritaire sur l'ensemble des réponses des trois classifieurs basés sur les approches utilisées (Kmeans, FCM et GMM). La fonction de décision combinée consiste à affecter correctement à chaque objet x la classe qui correspond à la majorité des votes des méthodes de classification. Un cas de rejet peut se présenter en cas d'égalité des nombres de votes pour chaque classe.

Ayant étudié trois types différents de *clustering*, le cas de rejet n'est pas évoqué dans ce travail.

4.3.3.2 Méthode de la somme pondérée

La méthode du vote par la somme pondérée est une généralisation de celle du vote simple dans lequel chaque classificateur individuel peut être associé à un poids différent [WKB97].

Le vote avec pondération consiste à attribuer aux réponses des classifieurs une valeur pondérée par un coefficient indiquant leur importance dans la combinaison.

Dans la littérature, on distingue deux types de vote par la somme pondérée : la pondération dynamique et la pondération statique des classifieurs.

Dans le cas dynamique, le poids attribué à chaque classifieur varie en fonction du vecteur d'entrée. Cependant, une fois que le poids du classifieur est calculé par l'approche statistique, il est utilisé pour toutes les entrées du système.

Dans le travail de combinaison réalisé, nous avons considéré le cas de pondération statistique. Afin de prendre en considération l'importance que peut avoir un classifieur par rapport aux autres, nous utilisons le degré de reconnaissance de chaque classifieur comme mesure d'importance. Ce degré d'importance est préalablement calculé dans la phase d'apprentissage puis il est impliqué dans la phase de test.

Considérant que $R1_i$, $R2_i$ et $R3_i$ sont les réponses de chaque classifieur associées à l'objet i et que $C1$, $C2$ et $C3$ sont les degrés de confiance de ces trois classifieurs, la pondération de chaque objet i est calculée en utilisant l'expression suivante:

$$R_i = \frac{R1_i \cdot C1 + R2_i \cdot C2 + R3_i \cdot C3}{C1 + C2 + C3} \quad (4.14)$$

Ainsi le résultat de la combinaison sera pondéré par la mesure R_i . A ce stade on peut proposer un seuil qui, en fonction de sa valeur, permet de conclure sur l'attribution de l'objet à une classe donnée ou bien le rejet de la classification.

4.3.4 Tests et évaluation des résultats

L'évaluation des performances de notre système est un enjeu de grande importance vu que ces performances peuvent être utilisées pour l'apprentissage. Plusieurs choix sont possibles concernant la mesure de performance.

Étant surtout intéressés par la classe des objets marquants nous considérons :

- le taux de bonne classification, c'est-à-dire le nombre d'objets marquants d'une base de test correctement classés ;
- le taux de fausse détection présentant le nombre d'objets marquants réellement présents dans la base et non détectés par le système.

Pour réaliser les différents tests, nous avons utilisé une base de données comprenant 1059 images simulées présentant des objets géométriques. Cette base contient des objets de formes, distributions et fréquences d'apparition variées tout en respectant les contraintes liées à un objet marquant (différent et peu fréquent). Nous considérons également que ces images sont les résultats de notre approche de segmentation, donc binaires. Aussi, nous considérons que les objets de forme compliquée (non structurés) sont les objets ordinaires et que les objets de forme simple

présentent la classe des objets marquants.

Un exemple d'image de test est présenté sur la figure 4.4.

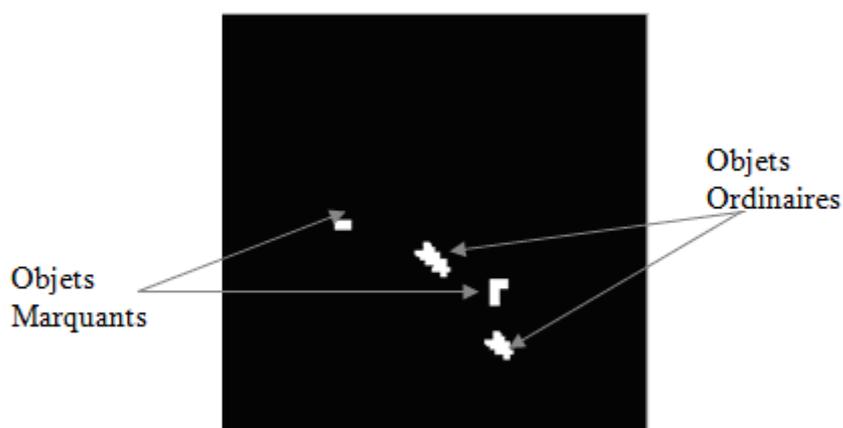


Figure 4.4: Exemple d'une image de test issue de la base de données synthétisées.

Notre base de données est partagée en deux groupes : 75% des données sont utilisées pour l'apprentissage et 25% sont utilisées pour les tests.

L'évaluation des résultats est réalisée en calculant le taux de succès de détection et le taux de mauvaise détection des objets marquants en les comparant avec les images vérités terrains. Les mesures que nous avons évoquées utilisent la matrice de confusion présentée dans le tableau 4.1. Cette matrice permet la différenciation des erreurs selon chaque classe en vue d'évaluer chacun des trois classifieurs et la méthode de leur combinaison.

	Présence objet marquant	Absence objet marquant
Étiquette Positive	Vrai Présence <i>VP</i>	Faux Absence <i>FA</i>
Étiquette Négative	Faux Présence <i>FP</i>	Vrai Absence <i>VA</i>

Tableau 4.1: Matrice de confusion de classification marquant-ordinaire.

A partir de la matrice de confusion, on définit les mesures suivantes :

- Le taux de vraies détections des objets marquants : $Tvd = \frac{VP}{VP+VA}$
- Le taux de vraies absences des objets marquants : $Tva = \frac{VA}{VA+FA}$

- Le taux de fausses présences des objets marquants : $Tfd = \frac{FP}{FP+VA}$
- Le taux de fausses absences des objets marquants : $Tfa = \frac{FA}{FA+VA}$

Après avoir testé les trois classifieurs sur une base de 353 images (190 objets marquants et 785 objets ordinaires), nous avons obtenu, pour la distance de Mahalanobis, les taux de reconnaissance et de fausse absence respectivement des objets marquants suivants :

K-means 64% et 34%, FCM 82% et 17%, GMM 37% et 60%.

Les performances obtenues après la combinaison des trois classifieurs sont :

- Pour le vote simple 69% de reconnaissance et 31% de fausse absence ;
- Pour la somme pondérée 87% de reconnaissance et 13% de fausse absence.

Ces résultats sont présentés dans les deux graphes 4.5 et 4.6.

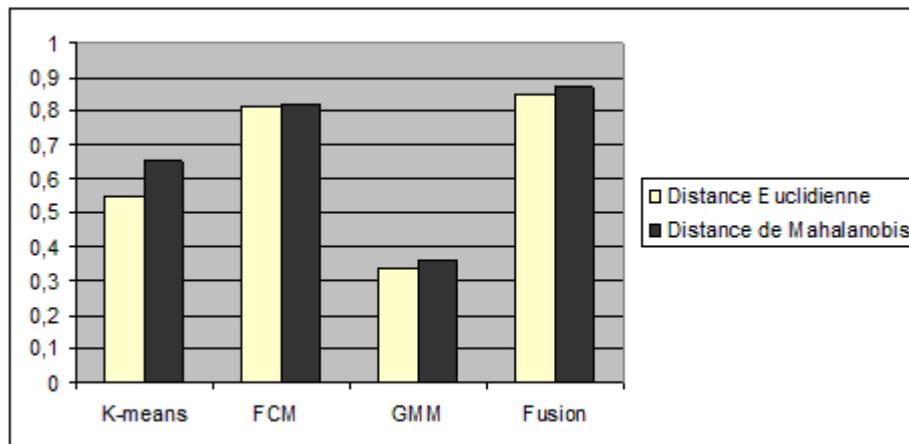


Figure 4.5: Évaluation des performances des trois classifieurs et du résultat de combinaison en taux de reconnaissance des objets marquants (max=1).

Nous avons constaté, à partir des résultats obtenus, que le mélange Gaussien propose une faible performance de détection des objets marquants. Il est ainsi, dans la majorité des cas, incapable de distinguer les objets qui s'écartent significativement de la majorité des objets. D'autre part, la fusion des classifieurs permet de réduire l'erreur de classification et la combinaison des classifieurs peut donner de bons résultats. Un exemple de ces résultats est présenté sur la figure 4.7. Cette figure présentait une capture d'écran des résultats des différentes classifications. Ces résultats sont obtenus en testant les différents classifieurs sur une image de test et en appliquant le principe du vote pour la combinaison des résultats.

D'après nos tests, nous avons aussi remarqué que lorsque les objets ordinaires présentent des formes très étranges, le système les classe dans le groupe des objets marquants. Un exemple concrétisant ce résultat est présenté sur la figure 4.8.

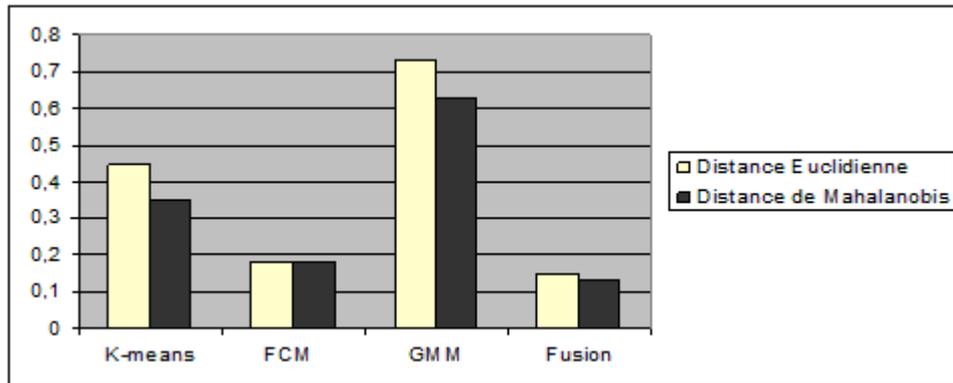


Figure 4.6: Variation du taux des fausses absences des objets marquants pour les trois classifieurs et résultat de combinaison (max=1).

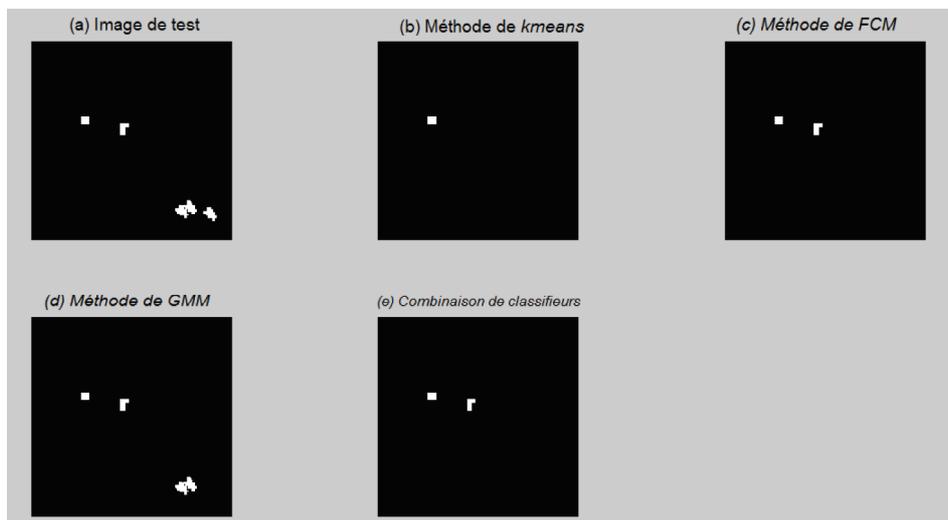


Figure 4.7: Classification de l'image de test en utilisant différents classifieurs et résultats de la combinaison.

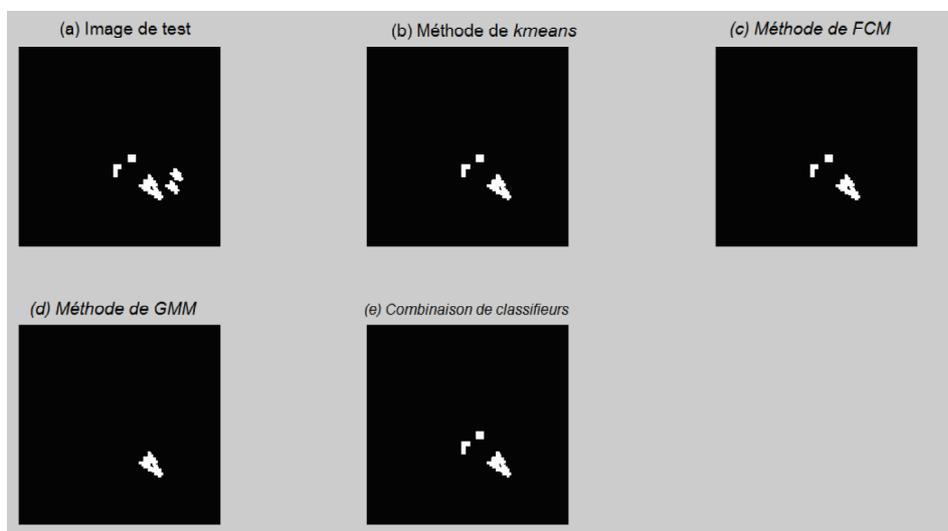


Figure 4.8: Exemple de résultats de fausses classifications des objets habituels.

4.4 Détection des objets rares : application de la saillance visuelle

Nous présentons dans cette section l'étape finale du processus de détection qui consiste à extraire les objets rares à partir de la classe des objets marquants. La figure 4.9 illustre le processus de la détection finale des objets rares.

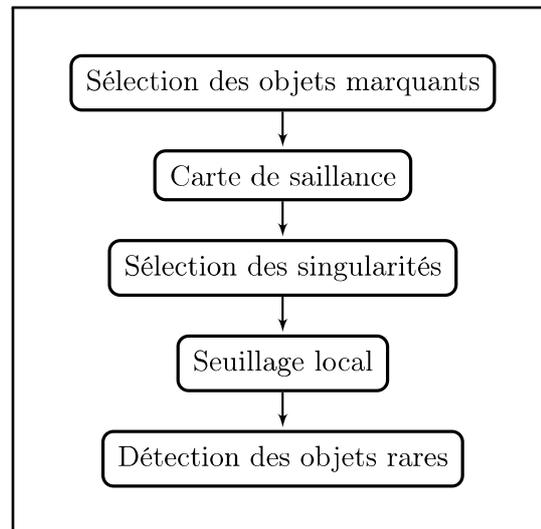


Figure 4.9: Diagramme illustrant la détection des objets rares à partir de la base des objets marquants.

Notre objectif est alors de détecter les objets saillants présents dans la classe des objets marquants. Ces objets sont certes des objets inhabituels, mais de plus ils présentent d'autres propriétés qui les différencient tant des objets marquants. Notre idée, pour discerner les objets rares est d'utiliser un algorithme de saillance visuelle en considérant les résultats de *clustering*. Notre contribution consiste à exploiter les propriétés des objets à la fois dans le domaine spatial et fréquentiel pour localiser l'objet recherché. Nous utilisons une technique de détection de saillance dans le domaine fréquentiel que nous adaptons à notre objectif.

4.4.1 Rareté et saillance visuelle

Naturellement, le terme saillance implique la rareté. En effet, et compte tenu de certaines caractéristiques, les objets les plus rares sont les plus saillants. Schiele, dans son travail [Sch97], a montré que les points les plus saillants dans un objet sont exactement les points les plus singuliers. Il considère que ces points maximisent la discrimination entre les objets. De même, Mancas *et al.* [MGM07] ont traité la rareté en équivalence avec la saillance.

Dans le cadre de la fouille des données, un objet est saillant s'il est facilement détecté. De nombreuses études ont été réalisées depuis une vingtaine d'années pour mesurer la saillance. Typiquement, la mesure de saillance repose sur la perception

du système visuel humain (SVH).

La modélisation de la vision humaine est depuis toujours un défi informatique qui implique l'étude de l'attention humaine. L'attention visuelle réfère au processus permettant de concentrer l'esprit sur les objets particuliers. Ces objets stimulent l'attention visuelle et impliquent leur localisation.

On distingue principalement deux types de saillance : la saillance attentionnelle et la saillance de recherche. La saillance attentionnelle mesure la capacité d'attirer l'attention. La saillance de recherche s'intéresse à la facilité de trouver un stimulus donné lorsqu'on le cherche.

Dans le cadre de notre sujet de thèse, nous sommes particulièrement intéressés à la saillance attentionnelle. Nous présenterons dans la suite les techniques de détection des objets basées sur l'attention humaine.

4.4.2 Carte de saillance

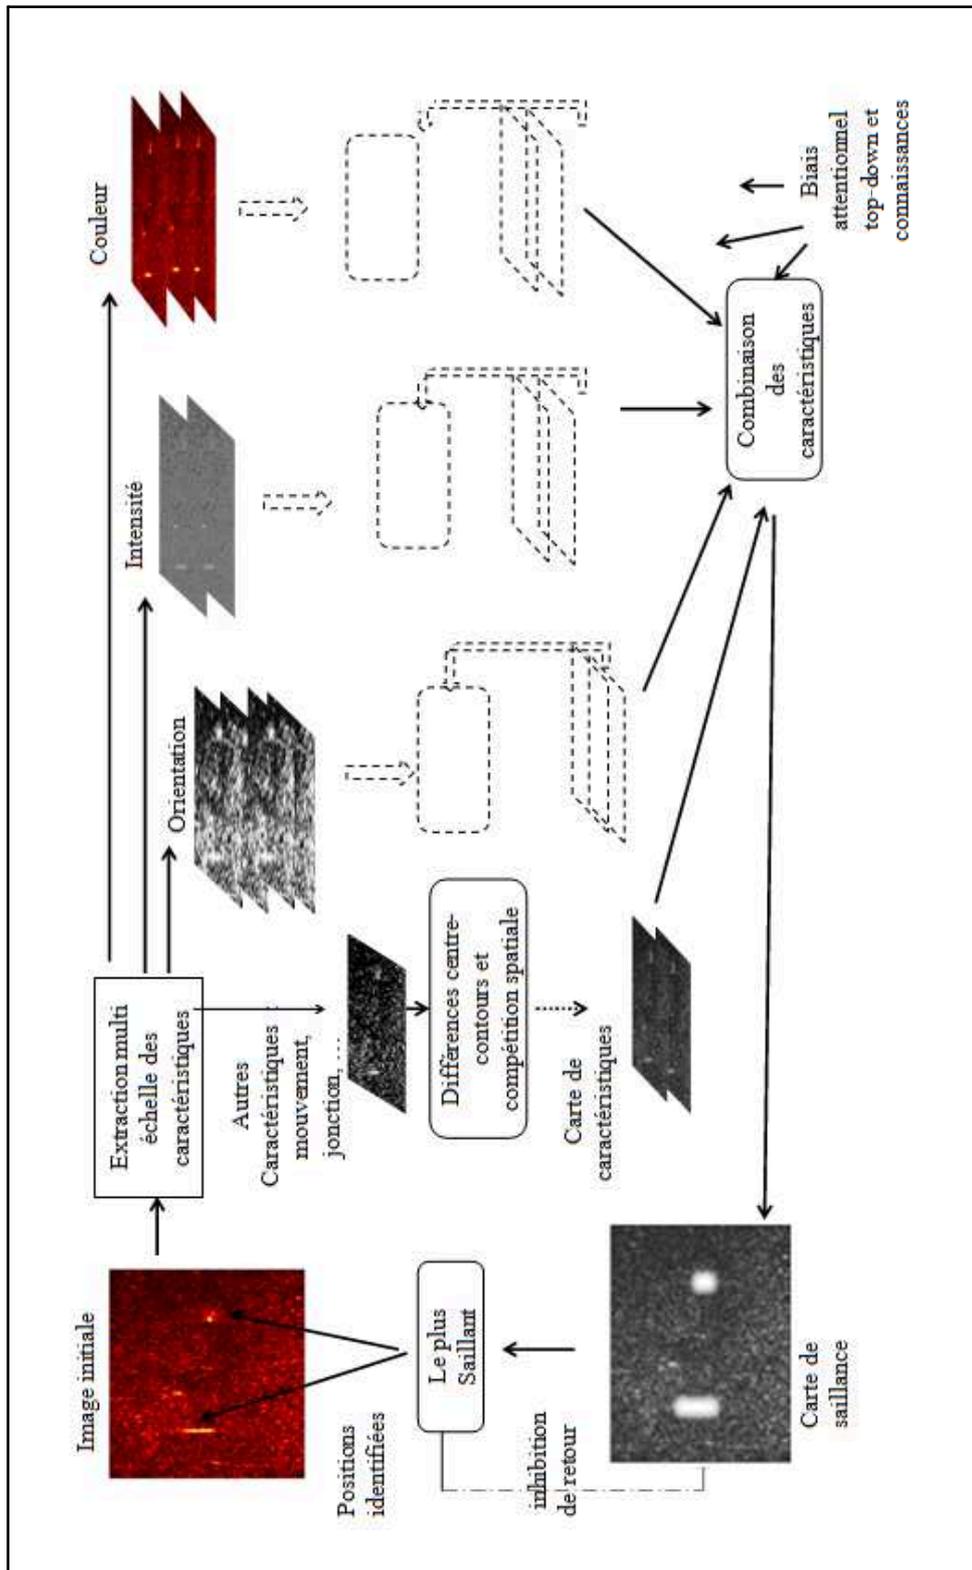
Dans la littérature, plusieurs travaux de recherche visent à proposer un modèle informatique de modélisation de l'attention visuelle.

Les modèles de Koch et Ullman, Itti et Treisman [KU85, LCN98, TG80] présentent les références de la littérature pour le calcul de la saillance. Ces modèles permettent d'imiter, d'une façon simplifiée, le fonctionnement du système visuel vis-à-vis de l'information visuelle sur la rétine et dans les premières couches du cortex visuel.

Les cartes de saillance présentent la technique la plus utilisée pour conceptualiser les mécanismes liés à la saillance. À partir de ces cartes de saillance, les points d'attention visuelle peuvent être extraits. Le calcul de la carte de saillance pour une image donnée permet ainsi de sélectionner les régions les plus saillantes dans la scène.

Les systèmes de recherche des régions saillantes de la scène visuelle, en calculant les cartes de saillances, peuvent être schématiquement décrits dans la figure 4.10 et en suivant les étapes suivantes :

- Extraction d'un certain nombre de caractéristiques de la scène. Les auteurs du modèle référence considèrent notamment comme attributs : la couleur, le mouvement, l'orientation et la taille ;
- Construction des cartes d'évidence pour chaque caractéristique. Ces cartes contiennent les points saillants de la scène pour chaque caractéristique ;
- Calcul des cartes de saillance partielles pour chaque position dans la scène visuelle. Ces cartes sont les résultats d'une combinaison des cartes d'évidence. D'une façon plus simple, la carte de saillance peut être définie comme étant la moyenne des différentes cartes d'évidence.
- Les zones de forte saillance sont présentées comme des disques de taille fixe autour des maximums locaux de la carte de saillance.

Figure 4.10: Système d'attention visuelle *bottom-up*.

Ce mécanisme d'attention est totalement guidé par les données et ne considère aucune connaissance *a priori* sur la scène.

Nous présentons brièvement dans le chapitre suivant différentes autres techniques de détection se basant sur le concept de la carte de saillance.

Comme dans le domaine transformé, les objets ont d'autres caractéristiques plus simples et en nombre réduit; nous choisissons d'employer une technique de détection de la saillance dans un domaine fréquentiel pour les objets rares. Nous présentons, dans la partie suivante, autres techniques de détection de la saillance dans le domaine transformé.

4.4.3 Techniques de détection de la saillance dans le domaine transformé

Les modèles de la détection de la saillance visuelle sont très variés et les caractéristiques utilisées pour la détection de la saillance diffèrent largement d'un modèle à un autre.

La première approche de détection de la saillance dans le domaine spectral a été introduite par Hou et Zhang [HHN06]. Dans leur travail, ils proposent de déterminer la mesure de la saillance en calculant la différence entre la perception résiduelle du spectre et le spectre des caractéristiques des pixels en niveau de gris. Dans leur algorithme, seule l'amplitude du signal est calculée et la composante de la phase n'est pas prise en compte. Guo *et al.* [GMZ09] en se basant sur le travail de Hou et Zhang [HHN06] ont prouvé que l'utilisation de la transformée de Fourier inverse du spectre de la phase conduit aux mêmes résultats. Plus tard, Guo *et al.* [GMZ09] et Bian et Zhang [BZ09] étendent leurs modèles de détection de saillance en ajoutant la caractéristique de la couleur.

Un nouveau modèle de détection de la saillance basée sur la sensibilité du système visuel humain (HVSAS) et les transformées de Fourier quaternioniques (TFQ) est introduit dans [FLL⁺12]. Le modèle de HVSAS utilise le spectre d'amplitude du QFT pour représenter la couleur, l'intensité et les distributions d'orientation pour les patches d'image. La valeur de la saillance pour chaque patch de l'image est calculée en considérant la différence entre le spectre d'amplitude QFT et la sensibilité visuelle humaine. Un modèle de détection de saillance plus récent qui repose sur les ondelettes est introduit dans [ILF13]. Ce modèle exploite les caractéristiques de bas niveau obtenues dans le domaine de la transformation en ondelettes.

Dans la suite de notre travail, nous adapterons l'algorithme de Hou et Zhang pour extraire les objets rares à partir de la classe des objets marquants susceptibles de contenir les types recherchés. Notre choix est motivé par les raisons suivantes:

- Hou et Zhang se sont inspirés de la théorie de l'information pour décrire le contenu fréquentiel de l'image. Leur méthode proposée se base sur une analyse fréquentielle de l'image et n'utilise aucun paramètre ;
- Contrairement à la méthode proposée par Itti [LCN98], la méthode de Hou et Zhang n'utilise aucune caractéristique de l'image pour calculer la carte de

saillance ;

- Dans notre processus proposé, pour réaliser la phase finale de détection des objets rare, nous proposons une automatisation de la détection des régions saillantes. Dans la méthode de Hou et Zhang un seuil automatique est appliqué à la carte de saillance pour extraire les régions saillantes ;
- La méthode proposée est simple à mettre en œuvre et n'utilise pas de filtre pour déterminer les points saillants. Elle ne nécessite également aucune connaissance *a priori* de l'image.

4.5 Localisation finale des objets rares

Le modèle de Hou et Zhang est basé sur la représentation du spectre logarithmique de l'image et permet de détecter les zones de saillance dans une image donnée.

4.5.1 Algorithme implémenté

Pour caractériser les zones de saillance, Hou et zhang utilisent un algorithme du spectre résiduel. L'algorithme du spectre résiduel [HHN06] a pour objectif la découverte des propriétés du background en exploitant le spectre de puissance logarithmique. Il est basé sur l'observation selon laquelle le spectre logarithmique de plusieurs images présente des allures qui se rapprochent bien que les images contiennent des particularités statistiques. L'idée principale du spectre est de retirer les similitudes pour détecter la singularité correspondante à la saillance visuelle.

Pour adapter notre approche de détection au modèle décrit, nous tenons compte des déclarations suivantes :

- La classe des objets rares est obtenue en éliminant les composantes statistiques redondantes dans la base d'apprentissage des objets marquants ;
- Les zones des particularités statistiques dans la carte de saillance représentent les points saillants parmi les objets atypiques.

Notre approche est basée sur un apprentissage des données atypiques. Les étapes d'entraînement des données de la base atypique sont présentées dans le diagramme de la figure 4.11.

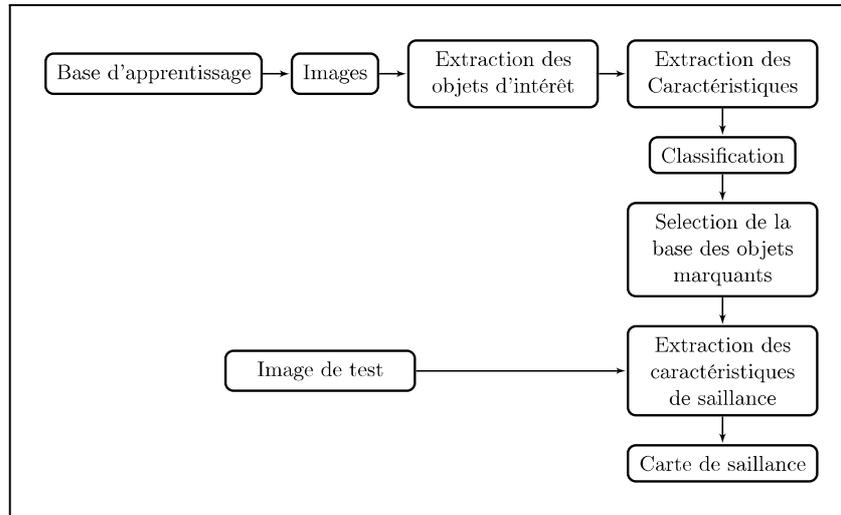


Figure 4.11: Diagramme illustrant la procédure d'apprentissage pour la détection de la saillance.

Considérant une image d'entrée I , f sa transformée de Fourier, A l'amplitude de f et $\log(A(f))$ la représentation de son spectre logarithmique, les détails de notre algorithme implémenté sont résumés comme suit :

1. Calculer le spectre logarithmique de l'image $L(f)$. Un exemple du spectre logarithme calculé pour l'image sonar de test est présenté sur la figure 4.12 ;
2. Calculer le spectre moyen de toutes les images de la base des objets marquants $moy(f)$;
3. Le spectre résiduel est obtenu à partir de l'expression suivante :

$$R(f) = L(f) - moy(f) ;$$
4. Appliquer la transformée inverse de Fourier sur le spectre résiduel et retour dans le domaine spatial.

Le résultat est présenté sur la carte de saillance où les objets les plus saillants (objets rares) sont localisés à partir des pixels correspondants aux valeurs les plus élevées dans la carte.

Dans la suite, nous souhaitons tester cet algorithme sur un ensemble d'images qui partagent des propriétés statistiques similaires mais, présentent également quelques singularités.

4.5.2 Tests et résultats

L'évaluation quantitative de notre approche de détection nécessite sa comparaison avec les avis des experts du domaine concerné. La phase de détection de saillance est évaluée en considérant des images vérité terrain correspondant aux points d'attention visuelle humaine.

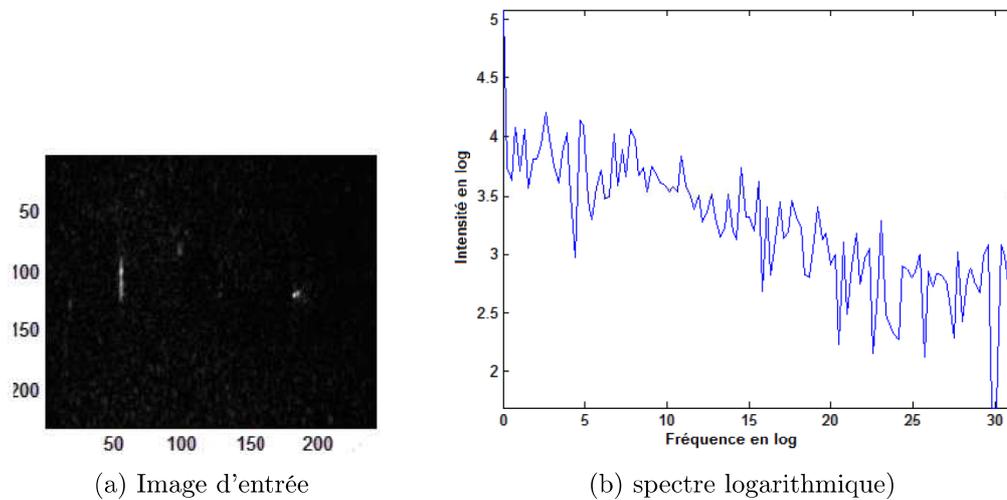


Figure 4.12: Exemple de spectre logarithmique de l'image sonar

Ainsi, nous faisons appel pour une deuxième fois à la base des images synthétisées que nous avons utilisé pour le *clustering*.

Notre but étant de détecter les objets rares parmi la classe des objets atypiques, nous procédons donc à l'application de l'algorithme proposé de la saillance visuelle sur la base des données considérées.

Nous présentons dans la figure 4.13 un échantillon des résultats que nous analysons visuellement.

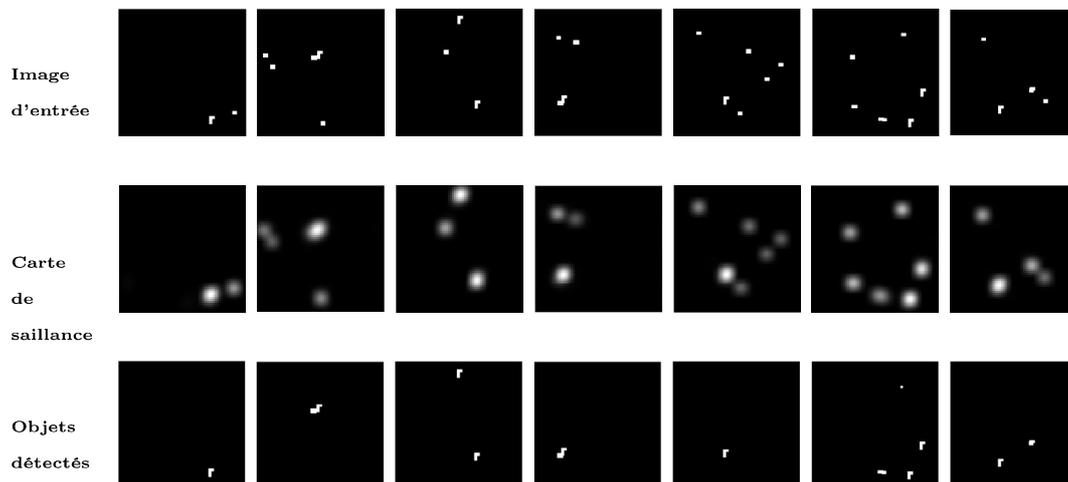


Figure 4.13: Détection de la saillance dans la base de données synthétisées.

Les objets détectés dans la figure 4.13 sont pratiquement les objets les plus saillants et possèdent donc le niveau de gris le plus utilisé. Une méthode de seuillage classique peut être utilisée dans cette phase finale du processus pour détecter des

objets rares.

Dans le travail réalisé, la valeur du seuil est déterminée en tenant compte de l'histogramme de l'image. Nous observons donc la distribution des différentes valeurs des pixels de l'image. Nous appliquons ensuite un seuillage simple en considérant une valeur seuil (S) de segmentation. Dans ce travail, la valeur de S est fixée manuellement, toutefois, plusieurs autres méthodes de segmentation peuvent être appliquées (Otsu, kmeans, ...).

D'une manière générale, l'algorithme proposé permet de détecter les objets qui présentent des singularités et sont peu fréquents dans la base. Cependant ce résultat devrait être confirmé et jugé par des méthodes de calcul de performances de détection que nous citerons dans le chapitre suivant.

4.6 Conclusions

Nous avons présenté les deux étapes principales de notre algorithme de détection : la pré-détection des objets rares et la détection finale des objets rares. La méthode proposée se base sur le calcul de la dispersion de l'objet du point de vue forme et sa distinction par rapport à tous les éléments de la scène où il se présente. Les résultats ainsi trouvés sont indépendants de la forme de l'objet et ne demandent pas de connaissances *a priori* ni sur l'objet ni sur l'image.

L'approche proposée peut être appliquée dans différents domaines. Elle permet de détecter un objet manufacturé dans une image naturelle (cas simulé) et fonctionne aussi dans le cas inverse : un objet non structuré dans une image contenant des objets structurés. L'extraction des autres caractéristiques de l'objet comme la texture de bord permet d'améliorer les résultats de détection basés essentiellement sur les invariants de Hu.

Cependant, la méthode présente de fausses détections lorsque l'image présente des objets ordinaires mais plus distincts. Un point faible de notre approche est le besoin d'une grande base de données pour évaluer la performance des résultats : en cas d'absence de données suffisantes dans la base, un objet marquant peut ne pas être détecté.

Systeme de detection d'un evenement rare

Sommaire

5.1	Introduction	121
5.2	Detection des objets rares dans une image medicale	121
5.2.1	Detection des microcalcifications	122
5.2.2	Description de la base de donnees	123
5.2.3	Pretraitements de l'image mammographique	124
5.2.4	Segmentation des zones d'interet: application de notre approche	126
5.3	Detection des objets rares dans une image astronomique	131
5.3.1	Différentes classes d'objets	132
5.3.2	Detection des objets marquants	132
5.3.3	Tests et evaluations	133
5.4	Systeme de raisonnement à base de cas	135
5.4.1	Qu'est-ce qu'un raisonnement à base de cas ?	135
5.4.2	Intégration de raisonnement à base de cas dans notre système	136
5.4.3	Processus	137
5.4.4	Différents modèles	139
5.4.5	Modèle textuel	140
5.5	RBC pour la detection des objets rares	140
5.6	Conclusions	144

5.1 Introduction

Dans notre algorithme proposé, la détection des objets rares est réalisée en deux étapes complémentaires. L'objectif de la première étape est de déterminer l'ensemble de toutes les données marquantes. Nous supposons que les objets recherchés sont englobés dans la classe détectée. Nous appliquons donc une méthode de détection de la saillance pour localiser les objets atypiques dans cette classe.

Les deux étapes de la détection sont fortement dépendantes et elles sont développées pour deux objectifs différents. Cependant, chacune des deux approches proposées peut être testée indépendamment lorsqu'on considère le sujet de la détection des objets atypiques dans un ensemble de données. C'est dans ce cadre que nous testons notre travail développé. Dans ce chapitre, nous nous sommes intéressés également à tester la méthode de prétraitement basée sur le seuillage homomorphique et la méthode de détection des objets d'intérêt basée sur l'exploitation de la courbe sigmoïde.

Ayant précédemment étudié le cas sonar, nous consacrons les parties expérimentales dans ce chapitre pour étudier le cas des images mammographiques et les images astronomiques.

Nous clôturons le présent travail par une étude de la possibilité d'intégration d'un système de raisonnement à base de cas (RBC) dans notre approche de détection. Nous exposons donc un état d'art du RBC en traitement d'image (TI) et nous discutons l'application du RBC pour la fouille des données rares.

5.2 Détection des objets rares dans une image médicale

En imagerie médicale, de nombreuses techniques développées visent à la détection d'objets inhabituels. Dans plusieurs types d'applications médicales, la détection de ces objets permet de réduire et de contrôler la dispersion d'une maladie donnée. Dans d'autres applications, la recherche des événements atypiques est fort utile dans la détection précoce des anomalies.

Les exemples d'application de la détection des objets rares dans le domaine médical sont très nombreux. Nous citons à titre d'exemples : la détection des cellules mutantes circulant dans le sang, la détection des tumeurs dans une image IRM (Imagerie par Résonance Magnétique) ou encore la détection des micro-calcifications dans une image mammographique.

Aujourd'hui, le cancer du sein est devenu la maladie la plus fréquente et mortelle chez les femmes [HKSD97, GRT93, Lan86]. Les spécialistes estiment que plus tôt la tumeur est détectée, plus le diagnostic et le traitement seront possibles et faciles. Dans plusieurs cas, les micro-calcifications sont la seule indication d'une tumeur maligne.

Nous considérons alors le cas de la détection des micro-calcifications en mammogra-

phie¹ pour tester nos approches développées dans le cadre de cette thèse.

5.2.1 Détection des microcalcifications

Les calcifications sont des éléments souvent interprétés par des mammographies. Elles sont de petite taille, généralement de 100 micromètres à 300 micromètres, mais, en réalité, elles peuvent atteindre une taille de $2mm$.

Les microcalcifications mammaires sont de minuscules dépôts de calcium présents dans le tissu du sein. Elles sont dues essentiellement à « des sécrétions cellulaires » ou encore à « des débris nécrotiques cellulaires » et se présentent sur les radiographies mammaires comme des taches blanches.

Habituellement, les microcalcifications sont la seule indication d'une tumeur maligne. La plupart des cancers du sein peuvent être détectés au stade précoce par la présence des microcalcifications en forme de grappes dans les images.

En effet, selon leurs tailles et formes, les calcifications peuvent être des pathologies malignes (petites calcifications de moins de $0,5mm$ de diamètre et de formes irrégulières) ou bénignes (grandes calcifications de forme régulière ronde ou ovale) [Her09].

Selon Le Gal [GC84], les différents types de microcalcifications peuvent être classés en cinq catégories de degrés de danger croissants, que nous présentons dans le tableau 5.1.

¹La mammographie est la technique d'imagerie la plus fiable pour détecter les tumeurs à un stade précoce. Actuellement, elle est considérée comme la principale source d'informations dans le dépistage du cancer du sein.

Type Le Gal	Aspect mammo-graphiques	Caractéristiques mammographiques
Type 1		Microcalcifications annulaires rondes à centre clair et transparent.
Type 2		Microcalcifications de formes rondes pleines et ayant les contours arrondis et réguliers .
Type 3		Microcalcifications de forme poussiéreuses et de taille trop fine.
Type 4		Microcalcifications de forme irrégulières et ayant des contours anguleux.
Type 5		Microcalcifications ayant la forme d'un bâtonnet souvent irrégulier.

Tableau 5.1: Classification des cinq types de microcalcifications de Le Gal.

5.2.2 Description de la base de données

Pour l'apprentissage de nos données ainsi que la réalisation des différents tests, nous utilisons la base de données MIAS (*Mammographic Image Analysis Society*).

La (MIAS)[[htt](#)] est un groupe de chercheurs britanniques qui étudient les images mammographiques. La MIAS a généré une base de 322 images de seins gauches et droits de 161 patientes. Les images sont au format JPEG et la résolution spatiale de chaque image est de 1024×1024 pixels.

Les images dans MIAS sont classées en trois classes principales : "normale", "bénigne" et "maligne". Il y a 208 images "normales", 63 images "bénignes" et 65 images "malignes". La base indique également les emplacements des anomalies probables en précisant le centre et les coordonnées sur les deux axes x et y de la zone "anormale". Ces anomalies ont été identifiées par des experts radiologues.

La base de données montre quatre types différents d'anomalies à savoir : Les densités asymétriques, les masses, les distorsions architecturales et les microcalcifications. Dans le cas de microcalcifications, la base de données contient 22 images étiquetées.

Dans notre travail, un échantillon de 222 images mammographiques à été extrait de la base de données MIAS. Nous considérons toutes les images avec microcalcifications et un ensemble de 200 images normales.

Nous proposons de détecter les micro-calcifications en utilisant notre approche

de segmentation. Nous considérons ainsi que les micro-calcifications sont les seuls objets d'intérêt que nous identifions comme événements rares dans notre base de données.

5.2.3 Prétraitements de l'image mammographique

Naturellement, dans une image mammographique, on distingue trois types différents de zones : le fond de l'image, la zone de tissu et la zone contenant des annotations et des informations. Au début du pré traitement, il nous paraît nécessaire d'effacer les zones d'informations afin d'éviter les fausses alarmes. Cela permet également d'alléger le calcul.

Étant donné que toutes les images sont à niveau de gris et que le fond de l'image est noir, nous proposons de segmenter l'image en ne considérant que les zones de taille considérable.

D'un autre coté, en mammographie, la taille de la partie sein présente la plus grande partie de l'image et occupe au moins 40% de la taille totale de celle-ci [YLH06]. Nous proposons ainsi de diviser l'image en zones connexes et de garder uniquement la grande zone. Notre approche n'est pas une méthode de segmentation à proprement parler. Elle permet seulement de découper grossièrement l'image en zones étiquetées.

Dans la pratique, nous utilisons la fonction prédéfinie de Matlab "bwlabel". Un exemple d'application de ce prétraitement sur une image mammographique est illustré sur la figure 5.1

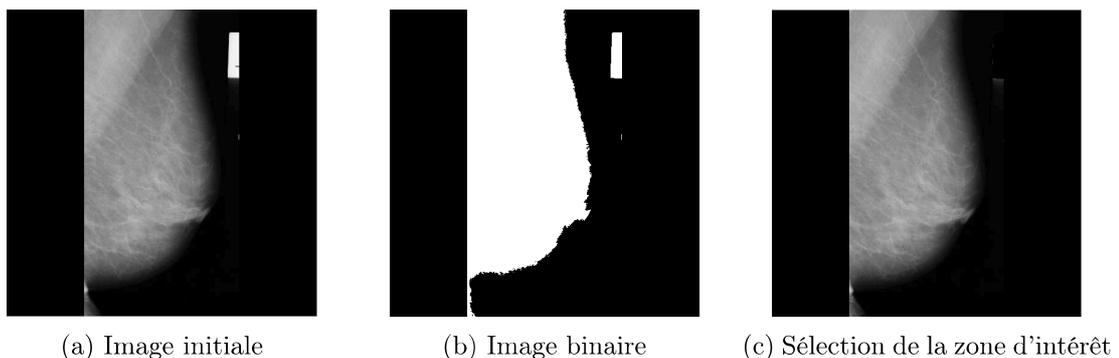


Figure 5.1: Prétraitement de l'image mammographique

Dans la suite, nous appliquons notre méthode de prétraitement sur l'image résultat. Nous examinons ainsi l'effet du filtrage homomorphique sur une image de mammographie en considérant le contraste et la luminance de l'image. Un exemple d'application de notre approche de filtrage sur une image de la base MIAS, après avoir enlevé les zones inutiles, est présenté dans la figure 5.2.

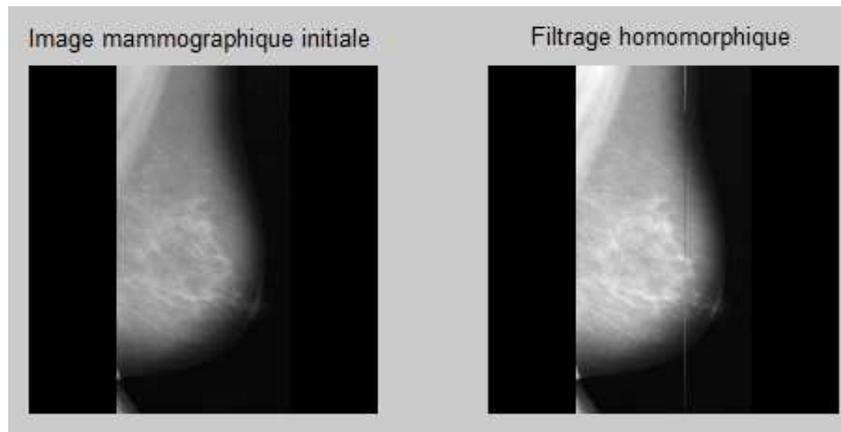


Figure 5.2: Application de la méthode de filtrage sur une image mammographique réelle (MIAS).

Le filtre homomorphique est testé avec une valeur de gain en basse fréquence $l = 0,4$, un gain en haute fréquence $h = 1,2$ et une valeur de coupure de fréquence $\delta_w = 0,2$.

En considérant l'exemple étudié, nous nous chargerons d'évaluer les performances de notre méthode de filtrage en appliquant les critères d'évaluation définis dans le chapitre de prétraitement (mesures de variance v et de distance d).

Nous considérons alors la partie "sein" (la zone "objet") et le fond de l'image. Nous procédons dans la suite à calculer les performances du filtrage homomorphique dans ces deux zones.

Afin d'évaluer le lissage de la partie fond de l'image mammographie nous avons calculé la variance de l'image avant et après le filtrage. La valeur numérique obtenue pour l'image considérée est $v = 3,61$.

En considérant que la zone sein dans l'image, nous calculons la valeur numérique de la mesure d . Ce critère permet d'estimer la distance entre les deux images avant et après le filtrage. En pratique, nous obtenons un résultat de $d = 0,12$. Cette valeur est considérée faible (inférieure à 1). La valeur de d est importante dans le cadre avec lequel elle évalue la préservation des données dans la zone la plus intéressante de l'image. Plus d est faible plus les données importantes dans l'image sont conservées et non altérées par le prétraitement.

Le filtrage homomorphique permet donc de rehausser les contrastes de l'image mammographique tout en diminuant le bruit de la zone "fond".

Dans la suite de notre travail, nous nous sommes intéressés uniquement à la zone "sein" et particulièrement par les régions d'intérêt dans cette zone. Nous considérons le résultat du prétraitement intéressant pour la suite de l'application de notre approche de détection.

5.2.4 Segmentation des zones d'intérêt: application de notre approche

Dans la littérature, plusieurs approches ont été proposées pour détecter la présence de micro-calcifications dans une image de mammographie. Plusieurs méthodes ont ainsi été proposées pour la segmentation et la détection des régions d'intérêt (*Region Of Interest*, ROI)[LLB⁺00, TFM99].

Dans cette partie de travail, notre but est d'appliquer la méthode de segmentation que nous avons développée pour détecter les objets d'intérêt. Nous examinons alors la courbe d'entropie et la variation des paramètres de la fonction sigmoïde résultant de la variation du seuil de segmentation de l'image.

En se basant sur les informations disponibles dans la base MIAS indiquant le rayon et le centre de l'anomalie pour chaque image, nous proposons d'appliquer la segmentation pour extraire les objets d'intérêt dans les zones suspectes.

La figure 5.3 montre un exemple d'image mammographique de la base MIAS où la zone d'intérêt indiquée par les experts est entourée en rouge.



Figure 5.3: Localisation de la zone d'intérêt dans une image de la base MIAS.

Comme les micro-calcifications ont des niveaux de gris plus élevés que le tissu et la classe "tissu" domine la région marquée, notre méthode de seuillage unimodal peut être utilisée pour trouver le seuil local dans la zone suspecte.

Sur la figure 5.4, nous présentons l'image de test et l'histogramme correspondant à la zone d'intérêt encadrée en rouge. Dans la zone marquée (la partie zoomée de l'image), on distingue deux classes : le fond de l'image (zone "tissu") et les objets d'intérêt (les micro-calcifications). L'emplacement du centre de l'anomalie est (439; 367) dans le plan (x, y) et le rayon approximatif du cercle entourant la tumeur est de l'ordre de 23 pixels. La figure montre une allure unimodale de l'histogramme de la zone considérée.

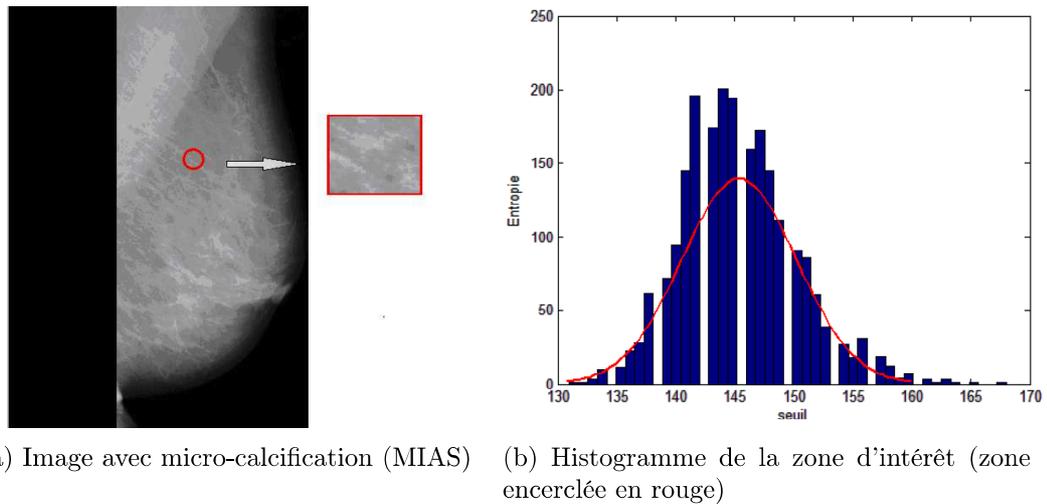
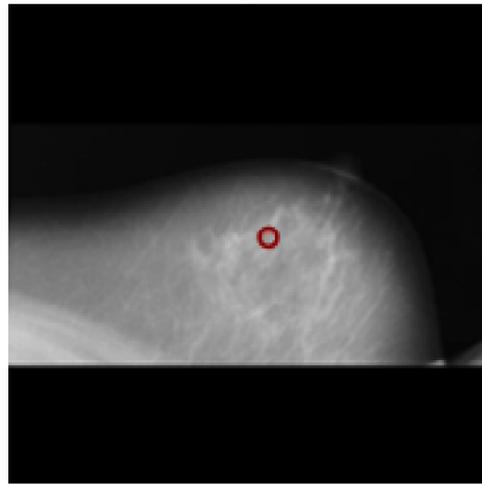
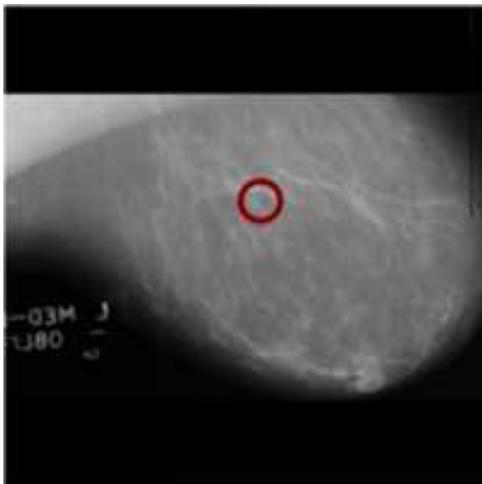
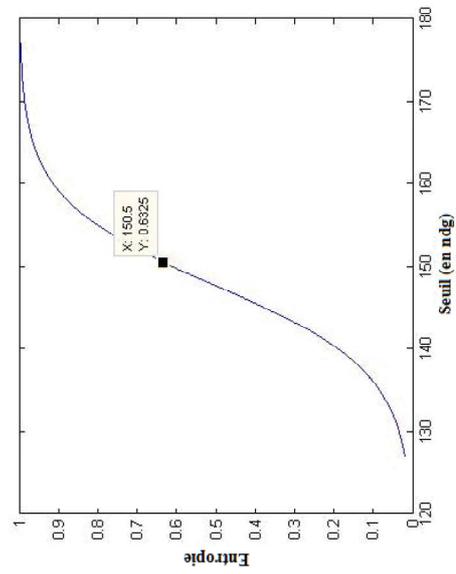
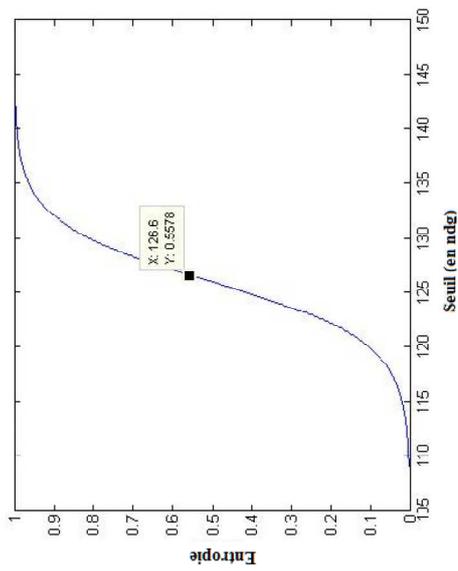
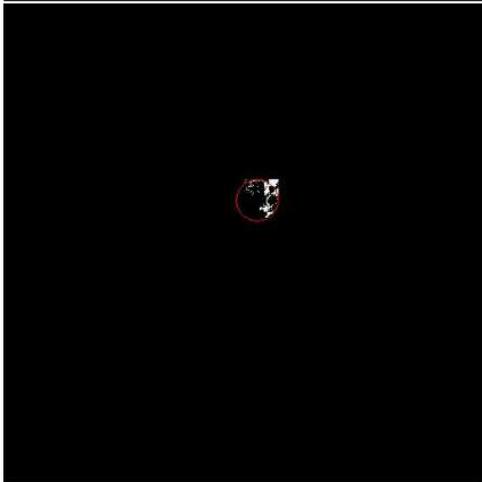


Figure 5.4: Illustration de la nature unimodale d'un exemple de zone d'intérêt dans la base MIAS

L'approche de segmentation consiste alors à classer les zones d'intérêt mammographiques en deux classes : les tissus normaux et les micro-calcifications. Pour chaque image de l'ensemble des images mammographiques de test, nous déterminons les valeurs des couples de paramètres de la fonction sigmoïde estimée (λ, t). Ensuite, nous appliquons l'algorithme de calcul de la valeur de seuil. Ainsi, nous calculons les fonctions dérivées et déterminons le niveau de gris correspondant au point d'inflexion dans la courbe. La figure 5.5 illustre quelques résultats de l'application de l'algorithme de seuillage sur un échantillon de quatre images de test.



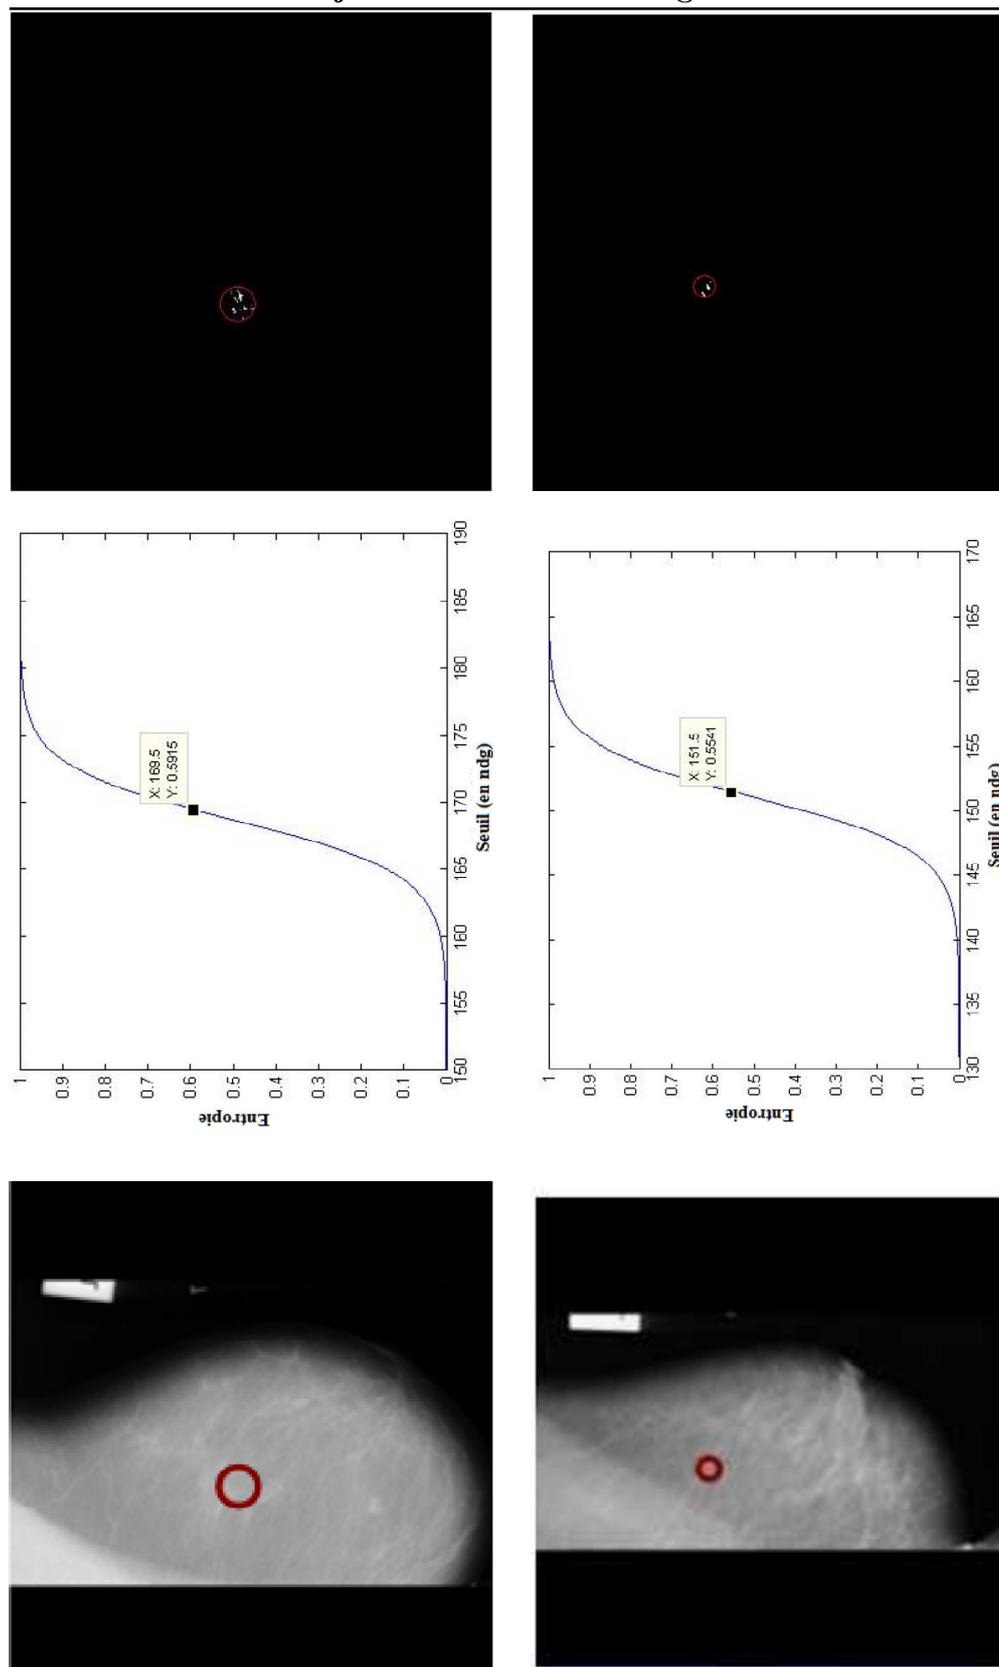


Figure 5.5: Application de notre approche de segmentation sur un échantillon d'images mammographiques présentant des microcalcifications (de MIAS). La première colonne présente les images avec la zone d'intérêt entourée en rouge, la deuxième présente les courbes résultats de l'application de la méthode de segmentation et la troisième colonne présente les résultats de la segmentation de la zone d'intérêt par les seuils résultants.

La valeur de seuil de segmentation est calculée en considérant le niveau de gris maximum dans la zone d'intérêt $max(g)$ et la valeur de point d'inflexion I de la courbe sigmoïde estimée tel que : $seuil = 2 \cdot max(g) - I$

Le tableau 5.2 présente les résultats numériques obtenus lors de l'application de l'approche de segmentation sur les images de la figure 5.5. Pour chaque image i (les quatre images sont nommées dans l'ordre suivant : Image 1, Image 2, Image 3 et Image 4), nous avons calculé l'abscisse du point d'inflexion et la valeur de seuil correspondante.

	Image 1	Image 2	Image 3	Image 4
Point d'inflexion	126,6	150,5	169,5	151,5
Seuil	111,2	124	158	138

Tableau 5.2: Calcul des paramètres de seuillage pour un échantillon d'images mammographiques.

Une évaluation possible du travail effectué peut être réalisée en exploitant les différentes possibilités de l'application de l'algorithme de seuillage. Selon que l'algorithme détecte ou non des objets d'intérêt dans la zone suspecte, et que la zone est réellement maligne ou normale, nous distinguons cinq cas possibles. La figure 5.6 illustre les différentes possibilités de l'application de l'algorithme de segmentation.



(a) Vrai positif (b) Vrai négatif (c) faux positif (d) faux positif (e) Faux négative

Figure 5.6: Illustration des différents cas possibles dans la matrice de confusion

Les zones d'intérêt sont entourées par la couleur rouge. Les points rouges désignent les micro-calcifications, résultats de la segmentation unimodale.

Les cas (a), (c) et (d) représentent les images étiquetées dans la base des données qui contiennent réellement des micro-calcifications.

Sur la première image (a), les micro-calcifications sont détectées dans la région où elles sont censées être situées. Sur l'image (c), l'algorithme de segmentation ne détecte pas d'objet d'intérêt alors que la zone suspecte est censée contenir des micro-calcifications. Dans le cas de l'image (d), les micro-calcifications sont détectées, mais pas dans la région où elles sont censées être présentes.

Les deux cas (b) et (e) désignent des images de patients sains. Pour le cas de l'image

(b), l'algorithme de segmentation ne détecte pas d'objet d'intérêt alors que dans le cas de l'image (e), l'algorithme détecte des micro-calcifications qui n'existent pas réellement.

Ainsi, une évaluation des paramètres peut être réalisée en considérant les définitions suivantes:

- Sensibilité : la proportion de la vraie présence de micro-calcifications et qui sont prédit présents ;
- Spécificité : la proportion de la vraie absence de micro-calcifications et qui sont prédit absents ;
- Précision : la proportion de micro-calcifications qui sont prédits présents et sont réellement présents dans l'image ;
- Exactitude : la proportion du nombre total de prédictions qui sont correctes.

Pour appliquer notre approche de détection, nous avons besoin de l'avis d'un radiologue nous permettant de préciser les éléments malins parmi les objets détectés. En effet, la forme et la disposition des calcifications mammaires sont des indications pour la détection d'anomalies malignes [EPSJ98]. Par exemple, lorsque les micro-calcifications apparaissent regroupées en grappes elles présentent un indicateur important du cancer du sein pour les radiologues. Mais seuls les radiologues pourront décider de leur classe finale.

Malheureusement, la base MIAS ne contient pas les diagnostics des radiologues dans sa description. Étant donné que la détection des micro-calcifications devrait se faire à un niveau haut de spécificité, nous proposons de traiter l'algorithme de détection dans un autre domaine d'application.

5.3 Détection des objets rares dans une image astronomique

L'astronomie est une science qui a toujours fasciné les chercheurs, et qui vit de nos jours une révolution de l'information.

Le traitement des images astronomiques a pour but d'étudier et d'analyser les différents objets et phénomènes observés dans le ciel. Naturellement, il existe plusieurs applications intéressantes de traitements des images astronomiques tels que cataloguer les informations provenant d'énormes quantités d'images du ciel, l'automatisation du regroupement des galaxies, et le perfectionnement des outils de visualisation interactifs [JT81].

Actuellement plusieurs travaux de recherche se sont intéressés à la détection et la reconnaissance d'objets atypiques dans l'imagerie astronomique [CCMA15, JT81]. La reconnaissance de nouveaux types d'objets dans les images astronomiques contribue à la révolution de la science par la découverte de nouveaux types d'objets astrophysiques, à savoir des galaxies, nébuleuses, étoiles, amas,...

Étant particulièrement intéressés par la détection des objets rares, nous expliquerons, dans la suite, le cadre d'application de notre travail réalisé pour la détection des objets atypiques dans une image astronomique.

5.3.1 Différentes classes d'objets

Le cas astronomique est un excellent exemple pour l'application de notre approche de segmentation.

En effet, ceci est principalement lié à la quantité considérable de données à traiter et l'homogénéité des données au sein de la base des données. Un astronome dans son quotidien, observe un grand nombre d'objets dans le ciel. La plupart de ces objets sont bien expliqués par les théories et les modèles actuels. Le reste sont des exceptions. Sauf que la plupart de ces exceptions n'ont pas d'intérêt et seulement une faible représentation (0,001%) [PM04] de l'ensemble des données utiles. L'ensemble des objets présentant des anomalies par rapport à la classe des objets habituels forme la classe des objets marquants. Les exceptions, parmi les objets marquants, constituent la classe des objets rares.

5.3.2 Détection des objets marquants

Notre but, dans ce travail, est de tester notre approche de détection des objets marquants sur un ensemble d'images astronomiques. Cependant, en raison des obstacles technologiques et autres raisons externes, nous n'avons pas réussi à accéder à de vraies images astronomiques pour effectuer les tests. Nous avons donc eu recours à une base de données contenant des objets astronomiques synthétisés.

Considérant une image astronomique, une partie importante de son contenu est occupée par un ciel noir. Le reste est composé d'éléments classiques (étoiles, galaxies, ...) et seulement quelques données (si elles existent) présentent un intérêt pour les astronomes par leur rareté. L'histogramme de tels types d'images présente ainsi une allure unimodale avec une classe dominante présentant le fond et une autre présentée par quelques pixels et contenant les objets d'intérêt. Considérant la classe des objets d'intérêt nous distinguons deux types d'objets : les objets habituels (très fréquents et non importants pour l'astronome) et les objets marquants (peu fréquents et présentant des caractéristiques intéressantes à détecter).

5.3.2.1 Description de la base

Notre base d'images de données astronomiques synthétisées est créée en respectant les contraintes suivantes :

- Les images de la base sont toutes captées en considérant la même altitude ;
- La taille des objets d'intérêt (les objets captés) est négligeable devant la taille totale de l'image. Cette contrainte permet de garantir une allure unimodale de l'histogramme de l'image. Toutefois, les objets ne devront pas apparaître sous forme de points afin de ne pas détecter le bruit de l'image comme objet d'intérêt ;
- Une image donnée contient des objets de même nature, par exemple des étoiles, avec ou sans autre objet différent ;

- Les objets très fréquents dans la base sont de forme, orientation et taille peu distinctes. On peut, par exemple, respecter l'hypothèse que les objets les plus éloignés sont les plus petits ;
- Considérant la base de données, la proportion d'objets remarquables (autres que les étoiles pour le cas mentionné) ne devra pas dépasser 1% ;
- Pour un meilleur apprentissage, la taille de la base doit être de l'ordre de 1000 images.

Un exemple d'image de test de la base de données astronomiques est présenté sur la figure 5.7.

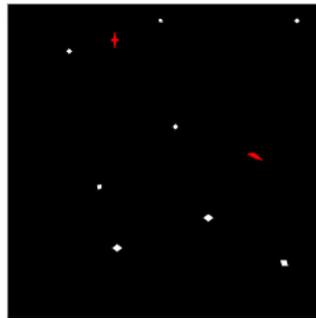


Figure 5.7: Image originale avec des objets astronomiques synthétisés.

Dans l'exemple de l'image de synthèse, nous schématisons en blanc les objets habituels de forme carrée et losange et en rouge les objets marquants de forme plus allongée et différente.

5.3.3 Tests et évaluations

Dans le but d'évaluer notre approche de détection, nous avons considéré une base de données de 1059 images synthétisées. Dans la partie expérimentale, nous utilisons 75% des exemples de la base pour l'apprentissage de données et l'ensemble qui reste pour les différents tests. Dans le processus de l'apprentissage, les résultats de la classification sont comparés avec les résultats de segmentation manuelle. L'évaluation des résultats est ensuite réalisée en considérant le taux de succès de la détection des objets marquants après usage des images vérité terrain.

Étant donné que la détection d'anomalie doit se faire avec un niveau critique de spécificité, nous admettons que cette mesure est la plus importante à considérer lorsqu'on cherche à détecter les objets atypiques dans une masse de données.

D'autre part, comme la mesure de précision reflète seulement la performance d'un classifieur à détecter les groupes redondants, et que nous sommes moins intéressés par la classe des objets fréquents, nous considérons seulement la spécificité et le taux de mauvaises classifications pour l'évaluation.

Pour calculer le taux de mauvaises classifications (ou encore de fausses alarmes), nous appliquons l'équation suivante : $Mauvaises\ classification = 1 - précision$.

Dans la pratique, la base d'apprentissage contient 353 images renfermant au total 190 objets marquants et 785 objets habituels. Nous comparons les performances de détection pour les différentes méthodes de *clustering* (*Kmeans*, FCM et GMM) et les méthodes de combinaisons de classifieurs en considérant les deux critères d'évaluation (spécificité et fausses alarmes). Les résultats d'évaluation obtenus, en considérant la distance de Mahalanobis, sont résumés dans le tableau 5.3.

Tableau 5.3: Mesures de performance pour la reconnaissance des objets marquants.

	Méthodes de <i>clustering</i>				
	<i>Kmeans</i>	FCM	GMM	Vote simple	Somme pondérée
Spécificité	91,40%	95,33%	82,93%	90,37%	96,54%
Fausse alarmes	19,02%	9,73%	26,23%	20,29%	8,06%

Les résultats montrent que le système de détection des objets marquants est assez performant pour séparer les différentes classes dans l'image. Toutefois, on constate que les résultats de détection les plus décevants sont obtenus par la méthode de mélange gaussien.

En effet, dans la plupart des cas, l'approche GMM est incapable de distinguer les objets qui diffèrent considérablement de la plupart des objets (des objets fréquents). Cette conclusion explique également la performance de la méthode de vote par somme pondérée par rapport à la méthode de vote simple: l'adaptabilité de la méthode de GMM permet d'erreur les résultats du vote.

Cependant, pour plusieurs tests accomplis, nous avons également remarqué que lorsque les objets ordinaires ont des formes très étranges, le système les considère comme des objets rares.

Pour une comparaison plus complète des performances de détection de la méthode de *Kmeans*, FCM, GMM et les techniques de combinaison, les courbes COR correspondantes sont présentées sur la figure 5.8. Le modèle FCM est plus performant que les deux autres techniques. Le *clustering* par la méthode de *Kmeans* est globalement plus performant que la combinaison de classifieurs par vote simple. Lorsqu'il s'agit de traiter une base de données de taille importante (en considérant le nombre d'objets), la méthode de classification par combinaison de somme pondérée est la plus appropriée parmi les différentes approches testées.

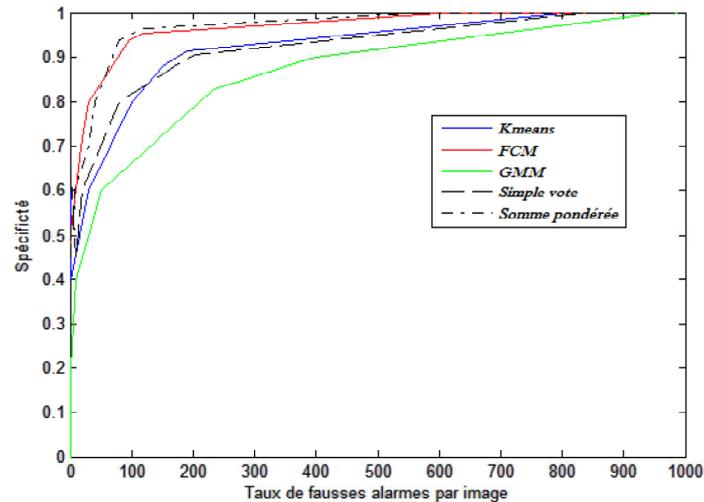


Figure 5.8: Courbe COR pour différentes approches de *clustering*.

5.4 Système de raisonnement à base de cas

Afin de respecter la contrainte de généralité et du manque de contexte et pour développer une approche totalement indépendante de toute information extérieure, nous avons opté pour une solution qui se base sur des connaissances générales. Cependant, une intégration de la connaissance spécifique dans l'algorithme de détection pourra améliorer notre système de détection de l'objet rare dans un domaine donné.

Le raisonnement à base des cas (RBC) est bien adapté à la résolution de ce genre de problème complexe. Il est particulièrement utilisé lorsque la tâche est accomplie par des humains expérimentés dans leur domaine et l'ensemble des expériences sont disponibles dans une base de données.

Ainsi, au lieu de compter seulement sur les connaissances générales ou faire des relations généralisées entre les descripteurs de problèmes et les conclusions, nous utilisons le RBC pour la réutilisation des connaissances spécifiques déjà rencontrées.

5.4.1 Qu'est-ce qu'un raisonnement à base de cas ?

Le raisonnement à base de cas (RBC) est une approche de résolution de problème appelé "cas" en utilisant des expériences passées enregistrées dans une base de données [Lea96]. La base de l'ensemble des expériences est appelée la base de cas.

Plusieurs études dans la littérature ont montré l'apport de l'intégration des situations spécifiques précédemment rencontrées dans la résolution de problèmes humains [Ros89].

Le RBC est bien adapté aux domaines où les expériences sont bien décrites dans des formats structurés comme les objets ou les enregistrements de la base de données.

Il est également appliqué lorsque la similarité entre les descriptions de problèmes fournit une indication de l'utilité des solutions antécédentes.

Examinons, à titre d'exemple, le cas d'un médecin qui analyse le résultat d'une mammographie d'un sujet malade et qui s'aperçoit que la tumeur détectée dans l'image médicale est similaire à un cas traité dans le passé. Le médecin utilise alors le diagnostic et le traitement enregistrés appartenant au patient d'un cas similaire, pour traiter le cas du patient en face de lui. Comme l'exemple le montre, un RBC désigne un problème (tumeur dans l'image médicale). Le cas passé est une situation précédemment expérimentée et enregistrée (description de la tumeur et du type de traitement) apprise de façon à être réutilisée pour résoudre dans le futur une autre situation similaire.

Globalement, la résolution de problèmes dans le RBC ne signifie pas forcément trouver une solution concrète d'un problème. Selon la description des cas dans la base, la solution peut être une confirmation ou un refus d'une solution proposée ou une interprétation d'une situation donnée.

5.4.2 Intégration de raisonnement à base de cas dans notre système

Pour améliorer les résultats de détection et avoir le bon réflexe face à un objet rare détecté, nous proposons d'intégrer un système de raisonnement à base de cas dans le processus de détection.

Le choix de ce type de raisonnement est lié aux raisons suivantes :

- Le RBC se base sur les connaissances des personnes spécialisées dans le domaine. La diversité des applications faisant appel à la détection des objets rares dans une image, requiert des experts spécialisés dans chaque domaine étudié (médecine, cartographie, géographie, . . .) ;
- Le RBC est une approche qui permet de combiner le processus et plusieurs types de connaissances favorisant ainsi l'exploitation et le partage des expériences passées.
L'utilisation de la description des objets en plus de l'avis de l'expert nous permet de garantir le résultat d'une détection souvent très critique ;
- Le RBC permet de simuler le raisonnement humain et permet d'intégrer les attentes et les exigences des utilisateurs dans le processus d'analyse des objets rares ;
- Le RBC est une approche incrémentale d'évolution des modèles des objets rares qui permet d'ajouter chaque nouveau problème résolu et le rendre immédiatement disponible pour de futures utilisations.

Notre but est d'appliquer un système de raisonnement à base de cas nous permettant de juger de la nature du traitement à appliquer face à un objet rare détecté en réutilisant des données déjà enregistrées dans la base des cas.

Considérant un objet rare, le raisonnement à base de cas extrait de la mémoire les

cas les plus analogues et les adapte pour juger du traitement à effectuer pour ce nouveau problème. La solution sera donc enregistrée pour une future utilisation. L'application de RBC dans notre système de détection implique une définition précise de cas. Typiquement, un cas est composé de deux parties. La première partie décrit le problème et contient la description de la situation. La deuxième partie décrit la solution utilisée pour remédier à cette situation.

Selon notre point de vue, le problème est défini par une image et par une description de l'objet rare, et la solution par un programme de traitement d'images à appliquer. Le programme pourra renvoyer un traitement similaire à celui appliqué face à un objet ordinaire contribuant ainsi implicitement à l'amélioration des performances de notre système de détection de l'objet rare.

5.4.3 Processus

Généralement, le raisonnement à base de cas peut se décomposer en quatre principaux processus : la recherche de cas, l'adaptation, la correction et l'apprentissage. La figure 5.9 illustre le schéma général du raisonnement à base de cas.

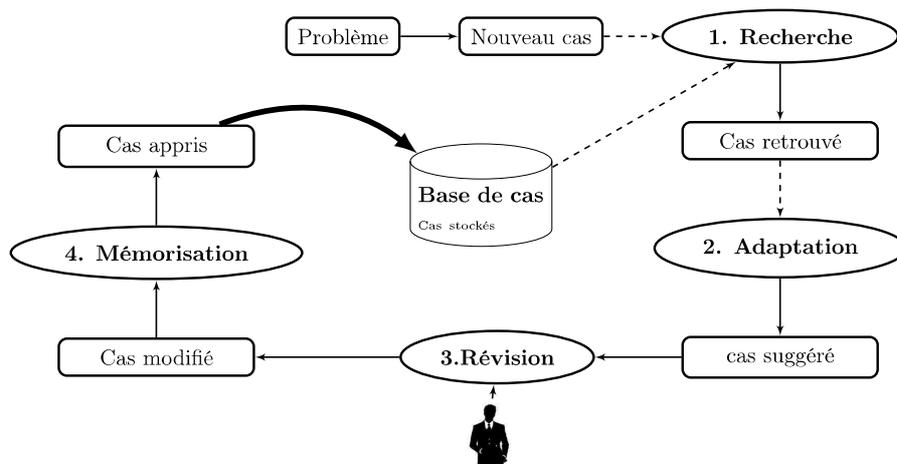


Figure 5.9: Cycle du raisonnement à base de cas.

5.4.3.1 Recherche de cas

Cette étape consiste à sélectionner les cas les plus proches du problème à résoudre. En général on distingue deux approches de recherche :

1. Approche des plus proches voisins : on utilise des métriques de similarité pour mesurer la correspondance entre chaque cas et le nouveau problème à résoudre.
2. Approche par induction : cette approche génère un arbre qui répartit les cas selon différents attributs et qui permet de guider le processus de recherche.

Typiquement, le processus de la recherche englobe trois tâches : l'identification de caractéristiques, la recherche initiale et la sélection. Le système utilise des moyens d'indexation dans chacune de ces tâches.

La tâche d'identification de caractéristiques nous permet de préciser les critères à prendre en compte pour la base de notre recherche. La tâche de recherche permet de retourner un ensemble de cas qui sont proches du cas courant. Pendant la phase de sélection, notre système devrait exploiter les cas renvoyés pour choisir le meilleur. Le système devrait alors posséder une mesure de similarité pour effectuer une sélection fine.

Nous proposons d'étudier les liaisons sémantiques pour une mesure de similarité plus performante. En effet, les approches sémantiques permettent d'utiliser le sens contextuel de la description du problème et le relier aux connaissances générales. Ainsi, pour définir notre système RBC, une connaissance importante du domaine est nécessaire.

5.4.3.2 Adaptation

Suite à la sélection des cas candidats lors de la phase de recherche, le système RBC propose d'adapter les solutions sélectionnées pour résoudre le problème courant. Lors de la phase d'adaptation, les solutions de cas candidats peuvent être modifiées puis réutilisées.

La phase d'adaptation implique naturellement deux étapes : déterminer ce qui doit être adapté et faire l'adaptation.

La première étape de l'opération se base sur la notion de la similarité pour établir le lien entre les connaissances nécessaires à cette étape et celles utilisées pour la phase de recherche. La deuxième étape de l'adaptation se base sur l'analyse du domaine. Lors de la phase de l'adaptation, le système examine toutes les données fournies par la description du problème courant pour mesurer leurs distances par rapport aux cas sélectionnés. Les anciennes solutions enregistrées dans la base sont donc utilisées comme source d'inspiration pour la résolution de nouveaux problèmes. Considérant notre cas d'application du RBC, nous proposons d'utiliser des stratégies d'adaptation différentes pour chaque domaine d'application. Ainsi, nous devons définir les connaissances nécessaires pour l'application de chaque type d'adaptation.

5.4.3.3 Révisions de cas

Le cas adapté renvoyé par la phase précédente peut être tout simplement inséré dans la base de cas. Cependant, lorsque la solution attribuée à ce cas n'est pas correcte, le système RBC permet la maintenance de ce cas pour s'instruire de ses échecs.

Cette phase est constituée de deux étapes : évaluation de la solution générée par l'adaptation et révision de la solution en cas de détection d'erreurs dans la solution courante.

La tâche de l'évaluation est généralement réalisée en se basant sur l'intervention d'un expert. La phase de la réparation de cas implique la correction de la solution courante afin d'optimiser les performances.

Considérant la révision des objets rares, les cas peuvent être modifiés si on change les attributs et leurs poids relatifs (la pondération qu'on a ajoutée à chaque attribut) en utilisant des informations spécifiques du domaine. La maintenance des bases de cas peut être guidée par les critères de la redondance entre cas.

5.4.3.4 Mémorisation

Dans cette étape, le nouveau cas est stocké de manière appropriée dans la mémoire de cas pour une future utilisation. Le cas est maintenant composé d'une partie problème, une partie solution, ainsi que tous les faits sous-jacents accomplis lors du raisonnement du système.

L'étape de la mémorisation permet également de déterminer les méthodes les plus efficaces pour effectuer l'indexation des nouveaux cas dans la mémoire. Ces indexes doivent être choisis de façon à ce que le nouveau cas puisse être rappelé lors du prochain raisonnement et appliqué lorsqu'il est le plus approprié.

Cependant, le cas ne devrait pas être sur-indexé car nous exigeons son étude dans un seul appel.

5.4.4 Différents modèles

Il existe plusieurs modèles de RBC. Ces modèles diffèrent considérablement les uns des autres en fonction de la manière de représenter des cas ou un raisonnement. On distingue trois familles principales de modèles : structurel, conversationnel et textuel [BAB⁺03].

5.4.4.1 Modèle structurel

Le modèle structurel de RBC est le plus utilisé. Il permet de définir une présentation de cas selon un vocabulaire structuré et commun. Dans ce modèle, les cas sont représentés par des paires <attribut, valeur>.

Le calcul de la similarité entre les cas se fonde sur la mesure de distance entre les valeurs des mêmes attributs. D'une manière générale, la distance euclidienne et la distance de Hamming sont appliquées lors du calcul de similarité. La similarité entre deux cas comparés est évaluée par une somme pondérée de la distance de chacun des attributs.

Nous considérons que les attributs d'un cas n'ont pas tous la même importance, donc le choix d'un modèle structurel nous amène à attribuer un poids à chaque attribut de chaque cas. Cette pondération contribua donc à évaluer la similarité globale entre deux cas en accordant une valeur plus importante aux attributs les plus significatifs.

5.4.4.2 Modèle conversationnel

Le modèle conversationnel vise à saisir les connaissances contenues dans les conversations client/ agent. Dans le modèle conversationnel, le problème à résoudre est

défini progressivement et la solution la plus adéquate est déterminée au fur et à mesure que le problème est défini [ABMA01].

Pour ce genre de modèle de RBC, un cas est défini par une brève description textuelle, une liste de questions et une description textuelle de la solution adéquate. La liste des questions est pondérée et varie d'un cas à un autre. Les poids attribués à chaque question permettent d'indiquer l'importance de la question dans la définition du problème.

Ainsi le modèle conversationnel ne propose aucune ontologie et aucune structure standardisée pour tous les cas. Le raisonnement est exclusivement basé sur la conversation homme/machine.

Typiquement cette interaction est réalisée en suivant les étapes suivantes :

- L'utilisateur fournit une brève description textuelle du problème à résoudre ;
- Le système calcule la similarité entre la description et la partie problème des cas présents dans la base des cas ;
- Le système propose une série de questions ;
- L'utilisateur choisit les questions auxquelles il souhaite répondre. Pour chaque réponse fournie par l'utilisateur, le système recalcule la similarité entre les cas ;
- Lorsqu'un cas atteint un certain niveau de similarité (i.e. il dépasse un certain seuil), le système propose ce cas comme solution. Si aucun cas n'atteint le niveau seuil de similarité, le problème est stocké comme étant non-résolu.

Le modèle conversationnel est le modèle RBC le plus utilisé dans les applications commerciales.

5.4.5 Modèle textuel

Le modèle textuel est adapté lorsque le raisonnement à partir de cas porte sur la résolution de problèmes à partir des expériences dont la description est contenue dans des documents purement textuels. Pour ce type de modèle RBC, il n'y a pas de structure commune de cas. Les cas sont représentés dans des textes de structure libre à savoir des chaînes [LA98].

Dans cette approche, les cas sont soit non structurés soit semi structurés. Lorsque la description de cas est effectuée en entier en langage naturel (en anglais *free-text*)², les cas sont non structurés. Ces cas, par contre, sont semi-structurés lorsque la description est découpée en portions étiquetées par des descripteurs (exemple problème, solution).

5.5 RBC pour la détection des objets rares

La multiplicité des domaines d'application de traitement d'image, s'intéressant à la détection et la catégorisation des objets rares, requiert une rapidité dans l'élaboration

²Contrairement au langage formel, le *free-text* est une langue « normale » parlée par un être humain.

de la solution en plus des experts en domaine. Une application de détection des objets d'intérêt peut nécessiter l'enchaînement de plusieurs opérateurs ainsi qu'un raisonnement associé à cet enchaînement.

Le RBC est une méthode de résolution des problèmes qui implique l'application des expériences passées pour déterminer une solution. En se basant sur ses caractéristiques, nous proposons un nouveau système de détection des objets rares basé sur le RBC. Ce système est construit en appliquant un raisonnement logique permettant de guider l'utilisateur souhaitant détecter et traiter les objets rares dans une image donnée. Le système proposé permet également d'améliorer les résultats de la détection grâce à l'intégration du RBC.

La figure 5.10 présente le diagramme de la méthodologie adaptée pour la détection des objets rares dans une image. L'entrée du système est une image naturelle. La sortie est une catégorisation des différents objets présents dans l'image ainsi qu'un type de traitement accordé aux objets appartenant à la classe « rare ». Le diagramme est subdivisé en cinq modules. Chacun de ces modules présente une étape principale du processus de détection et détaille les approches développées au cours de notre travail de thèse.

D'un point de vue plus général, le diagramme que nous proposons se compose de trois phases principales. La première phase, représentée dans le module I, englobe l'ensemble des opérations de prétraitement effectuées sur une image pour l'améliorer ou la restaurer. La deuxième phase du système comporte les modules II, III et IV. Au cours de cette phase, différents opérateurs et méthodes de traitement sont appliqués pour discerner les objets d'intérêt du fond de l'image. Cette phase devrait également fournir une caractérisation significative permettant de bien séparer les différentes classes de l'objet (habituel, marquant ou rare).

La troisième phase (module III) permet d'intégrer un système de RBC permettant d'assigner à chaque objet rare, détecté dans la phase précédente, le type de traitement à appliquer. Les résultats de cette phase dépendent fortement de la caractérisation de l'objet ainsi que sa représentation dans la base des cas.

Dans notre étude, les attributs de chaque objet (sémantiques et géométriques) sont fournis comme les données d'un cas, permettant ainsi une interprétation facile de données numériques.

Le tableau 5.4 présente une illustration de la représentation numérique des objets (cas). Chaque cas est composé de deux parties : une définition du problème (objet rare détecté) et une solution du problème (type de traitement à appliquer). Un cas est donc exprimé comme suit :

$$X = (X_1, X_2, \dots, X_n; T_k) \quad (5.1)$$

où X_n est la nième caractéristique reliée à un attribut géométrique ou sémantique et T_k représente le type de traitement à appliquer.

Une description simplifiée de la base de cas correspondante peut être donnée comme le montre l'exemple du tableau 5.5.

La base de cas contient les différents traitements à effectuer en considérant certaines mesures des attributs des objets. Elle est utilisée pour préciser le type de traitement à appliquer en évaluant le degré de similitude entre les cas candidats. À ce stade,

plusieurs techniques peuvent être utilisées pour mesurer la similitude citons à titre d'exemple la méthode de k-plus proches voisin et la distance de Manhattan.

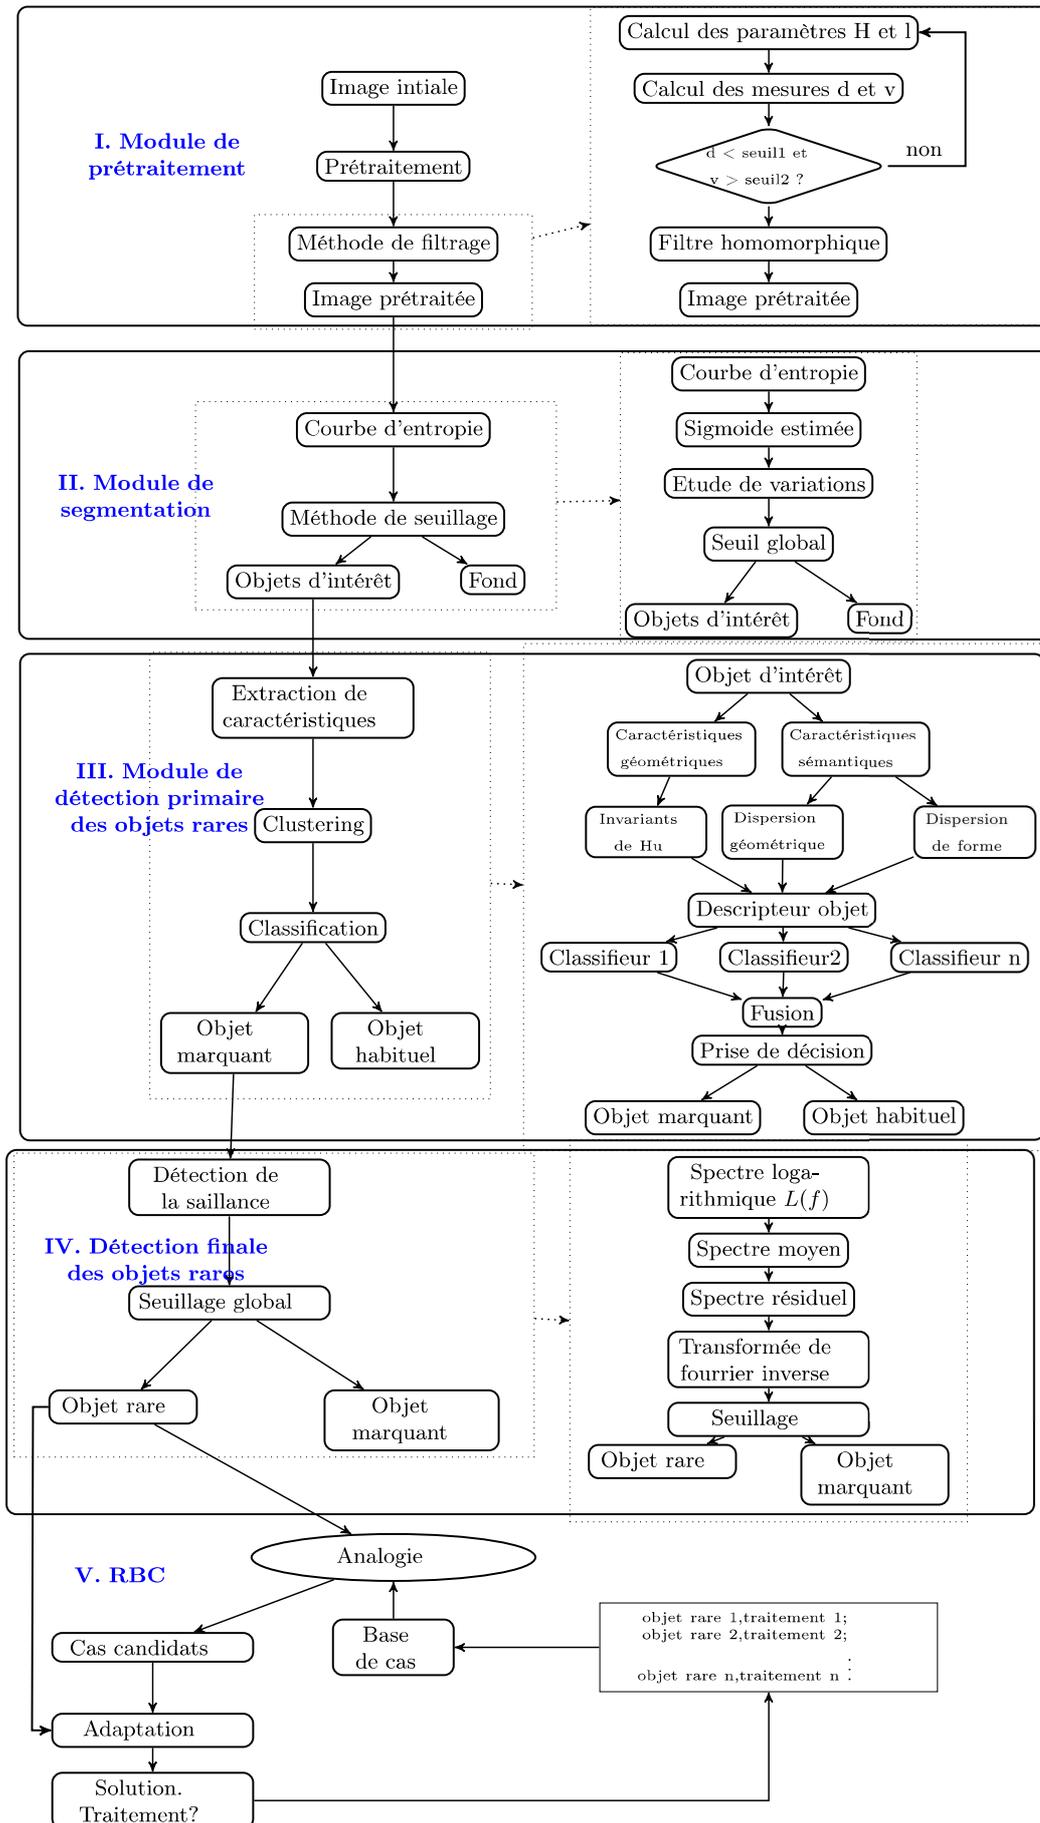


Figure 5.10: Structure du système proposé pour la détection des objets rares dans une image.

Id	Attribut1	Attribut2	Attribut3
1	**	**	**
2	**	**	**
n	**	**	**

Tableau 5.4: Représentation numérique des objets rares détectée dans une image quelconque.

Id	Attribut1	Attribut2	Attribut3	Traitement
1	-	-	-	traitement objet rare
2	-	-	-	traitement objet marquant
3	-	-	-	traitement objet marquant
N	-	-	-	traitement objet habituel

Tableau 5.5: Description de la base de cas

5.6 Conclusions

Dans ce chapitre nous avons étudié le problème de la détection d'objets rares dans deux domaines différents : la médecine et l'astronomie.

Dans le domaine médical, nous nous sommes intéressés au problème de la détection de microcalcifications dans une image mammographique. Nous avons testé l'approche de segmentation pour détecter les microcalcifications en exploitant les propriétés de la courbe de l'entropie . Ce travail peut être considéré comme un complément à celui effectué par les experts de MIAS où ils se contentent seulement d'entourer les zones d'intérêt.

Le manque d'information dans la base MIAS (types et natures des micro calcification) nous a empêchés d'évaluer notre approche de détection des objets marquants dans le cas d'une image médicale.

Dans la suite, nous avons procédé au test de cette approche dans le cadre astronomique également bien adapté à notre cadre d'étude. Les résultats obtenus avec des images réelles contenant des objets astronomiques synthétisés sont promoteurs. Toutefois, il est toujours intéressant d'appliquer cette méthode sur des images réelles.

Étant donné que la rareté est la caractéristique la plus importante des objets recher-

chés, l'obtention d'une base de données qui contient ces objets nous a été très difficile. Face à cette difficulté et pour anticiper dans les futurs traitements de ces objets, nous avons proposé d'appliquer un système de RBC. Un système de RBC nous permet d'intégrer les connaissances des experts souvent indispensables pour confirmer le type rare d'un objet donné. Aussi, ces objets seront -ils stockés dans la base pour de futures exploitations.

Dans ce chapitre, nous avons souligné les bases avec lesquelles nous intégrons le RBC. Ce système pourra faire l'objet de prochains travaux.

Conclusions et Perspectives

Le concept d'objet rare est très largement utilisé en sciences cognitives. Malheureusement, sa signification est loin d'être homogène et consensuelle. Les différentes appellations faisant référence à un objet rare varient considérablement selon les disciplines et les champs de recherche.

L'objectif de cette thèse est de proposer une approche générique pour la reconnaissance des objets rares dans une image naturelle. Cette thèse nécessite donc l'intervention de divers domaines du traitement d'images, principalement le pré-traitement, la segmentation et la classification. Dans ce manuscrit de thèse, nous avons présenté les contributions apportées dans chacune de ces étapes de processus de détection.

Afin de développer un système générique nous avons essayé d'appréhender l'être humain dans son raisonnement et d'intégrer la sémantique. L'idée générale de l'algorithme de détection est de réaliser une approche permettant de reconnaître chaque classe d'objet (habituel, marquant, rare) en des étapes successives et complémentaires.

Le système de détection des objets rares présenté dans ce travail est fondé sur l'identification de tous les objets d'intérêt dans l'image. Ensuite, la fouille des données utiles est réalisée sur deux étapes. La première étape a pour objectif de sélectionner l'ensemble des objets atypiques dans une image donnée. Cette phase permet de guider le processus de la détection vers l'étape de la sélection des objets les plus atypiques présentant la classe « rare ». La deuxième phase permet de sélectionner parmi ces objets marquants ceux qui sont saillants donc utiles au but recherché. Nous ne faisons aucune hypothèse sur la forme particulière des objets rares à extraire ou le domaine d'application. En conséquence, nous prévoyons que nos résultats peuvent être appliqués à de nombreux types de domaine d'applications. Ces résultats peuvent également fonctionner dans le cas contraire c'est-à-dire détecter un objet habituel dans une masse des données atypiques.

Naturellement, ces résultats peuvent toujours être améliorés si on intègre des connaissances extérieures au domaine d'application et encore plus si des experts interviennent dans le monde réel. Notre approche propose d'appliquer un raisonnement à base de cas assimilant ainsi des connaissances spécifiques déjà rencontrées dans le processus de détection, uniquement basé sur les connaissances générales. L'intégration du RBC favorise, en plus de la mise en œuvre des procédures de contrôle, une amélioration dans la qualité de la base des données rares. Les approches proposées sont largement évaluées sur plusieurs domaines de traitement des images (sonar, images contenant des objets manufacturés, médical, astronomique). Des expériences sur des images réelles ou de synthèses montrent que les approches proposées sont performantes.

Perspectives

Outre les pistes d'amélioration que nous avons proposées dans les différents chapitres de ce mémoire de thèse, nous proposons d'étudier les principaux axes de recherche suivants :

- Comparer les performances des approches développées, surtout dans les domaines de segmentation et classification, avec les travaux étudiés. Cette comparaison nous permet de positionner notre travail par rapport aux autres, de point de vue précision et efficacité.
- Tester le système proposé pour la détection des objets rares dans des domaines d'application complètement différents. En effet, pour évaluer à quel point l'approche proposée est générale, il est intéressant de l'appliquer dans des cas réels très éloignés des domaines étudiés. De point de vue théorique, l'approche proposée peut être appliquée pour la détection des éléments rares dans une masse de données textuelles. Par exemple dans le cadre de l'étude de la saillance linguistique, notre approche pourrait être utilisée pour déterminer les mots atypiques dans un texte donné. La rareté peut être définie soit comme l'incohérence entre les données dans un contexte particulier, soit comme ce qui diffère de l'habituellement observé.
- Réaliser un système de RBC appliqué au traitement d'images plus général que les systèmes existants. Le système réalisé doit gérer la phase de traitement d'images de sorte qu'on puisse l'appliquer à tout type d'analyse ou de domaine de l'image. Un cas est défini par l'image initiale et son domaine d'application et la solution de problème devrait fournir l'ensemble des traitements à réaliser si le système détecte des événements rares. Le système sera finalement intégré dans notre procédure de détection des objets rares. Pour définir l'architecture du système, nous devons tout d'abord étudier les différentes difficultés liées aux étapes du RBC. Nous limitons ces difficultés à l'étude de la représentation, la recherche et l'adaptation des cas.

Modélisation statistique de l'image sonar

A.1 Introduction

L'obtention du meilleur représentant d'un échantillon est une question ouverte unissant qui définit l'objet de plusieurs travaux de recherches dans des domaines variés.

Ce chapitre est composé de deux parties, chacune présente les résultats expérimentaux du travail de la modélisation statistique effectuée sur l'image sonar de test. Dans la première partie, nous procédons à chercher un bon modèle de représentation de notre image de test (image SAS) après application de la méthode de filtrage homomorphique. Nous examinons, alors, l'adéquation de la distribution de notre image de test aux autres distributions statistiques notamment la loi normale, la loi de Rayleigh et loi de Weibull.

Différents tests d'hypothèses sont réalisés sur l'image de test pour comparer la distribution empirique de l'image (son histogramme) à ces dernières distributions théoriques. Pour chaque test d'hypothèse, nous admettons que l'hypothèse nulle consiste à l'affirmation que l'échantillon initial suit une distribution donnée. Nous calculons aussi la probabilité de rejet à tort l'hypothèse nulle pour un risque $\alpha = 5\%$. Nous notons cette probabilité pour les différents tests effectués « p-valeur ».

Dans la deuxième partie, nous procédons à chercher un modèle probabiliste de la présence des objets dans l'image sonar. Considérant la linéarité de la courbe de la variation du paramètre de la sigmoïde en fonction du taux de l'occupation de l'image, nous présentons les résultats numériques de l'estimation de la courbe linéaire.

A.2 Tests d'hypothèses et analyse des résultats obtenus

A.2.1 Test de Shapiro-Wilk

Le test de Shapiro-Wilk est un test de normalité basé sur la statistique W et défini par l'équation suivante :

$$W = \max(|(Kp_i - n \cdot P_i)|, i = 1..N_{val}) \quad (\text{A.1})$$

avec K_{p_i} somme des réalisations de toutes les valeurs de niveau de gris inférieur à i et P_i valeur en i de la fonction de répartition associée à p_i . Ce test d'hypothèse est particulièrement puissant pour les petits effectifs ($n \leq 50$). Néanmoins, la statistique donne des résultats précis jusqu'à $n \leq 5000$. Ainsi, dans le cas de notre image SAS

(taille de l'image : (231×431)) on ne peut pas se servir de ce test pour étudier la statistique de notre population.

A.2.2 Test de Kolmogorov Smirnov

Le test de Kolmogorov Smirnov (KS) est, comme le test de Shapiro-Wilk, un test assez puissant et très souvent utilisé dans les travaux de la recherche scientifique. Le test de KS est un test non paramétrique et robuste. Ce test ne fait pas d'hypothèses par rapport à la population et permet de comparer une distribution empirique à une distribution théorique. Contrairement au test de ShapiroWilk, lorsque la taille de l'échantillon est très grande (> 30) le test de KS devient plus robuste. Nous appliquons ainsi ce test sur l'image de test en considérant que l'hypothèse nulle est la statistique de l'image suit une loi théorique donnée. Nous calculons aussi la valeur de « p-valeur » avec un risque $\alpha = 5\%$. A fin de juger le rejet de l'hypothèse nulle, nous avons également calculé la valeur de KS .

Ainsi si $p\text{-valeur} < \alpha$ on conclut le rejet de l'hypothèse nulle. Nous appliquons KS sur l'image sonar en considérant à chaque fois une distribution théorique différente (Loi normale, loi de Weibull et loi de Rayleigh). Les résultats de test de KS avant et après le filtrage homomorphique pour différentes hypothèses nulles (H_0 changent suivant le modèle statistique adopté mais conserve toujours la même forme) sont présentés dans le tableau A.1.

Image d'entrée	Statistiques du test	Loi normale	Loi de Weibull	Loi de Rayleigh
Image initiale	H	1	1	1
	p-valeur	0	$1,474 \cdot 10^{-16}$	0
	p-coupure	0,99	0,0581	0,1868
Image filtrée	H	1	1	1
	p-valeur	0	$7,708 \cdot 10^{-16}$	0
	p-coupure	0,99	0,0580	0,1678

Tableau A.1: Calcul des statistiques de test de KS pour l'image SAS avant et après le filtrage H.

La valeur de $H = 1$ indique le rejet de l'hypothèse H_0 . En conclusion, les différentes hypothèses effectuées ne nous permet pas d'obtenir un cas de confirmation de l'hypothèse nulle malgré l'amélioration de paramètre de « distance de Kolmogorov Smirnov » précédemment calculé.

A.2.3 Test de Lilliefors

Le test de Lilliefors est une variante du test de Kolmogorov-Smirnov, dans le cas de la distribution normale, où les paramètres de la loi (μ , σ) sont estimés à partir des données initiales. La statistique du test est calculée de la même manière que KS et les valeurs critiques sont évaluées pour un même risque α .

Les résultats d'application de ce test sur l'image SAS dans les deux cas, avant et après le filtrage homomorphique, donnent une valeur de p -valeur = 0,001. Ainsi, le test de Lilliefors, pourtant fondé sur la statistique de Kolmogorov-Smirnov, est plus conservateur, avec une valeur de p -valeur inférieure à celle obtenue avec le test de KS.

A.2.4 Test de khi-deux

Le test du khi-deux deux (ou chi-deux, ou χ^2) est un test d'hypothèse statistique non-paramétrique pouvant également être utilisé dans notre cas particulier pour tester l'adéquation d'une loi empirique à une distribution théorique. Considérant le cas d'une distribution normale, les résultats du test de Khi-deux sur l'image SAS avant et après son filtrage sont présentés dans le tableau A.2. Nous calculons également la valeur de χ^2 dans les deux cas ; c'est -à-dire avant et après le filtrage homomorphique.

Image d'entrée	Statistiques du test	Loi normale
Image initiale	H	1
	p-valeur	0
	Khi2	$2,10 \cdot 10^4$
Image filtrée	H	1
	p-valeur	0
	Khi2	$1,627 \cdot 10^3$

Tableau A.2: Test de normalité réalisé avec la méthode de Khi-deux et appliqué sur l'image SAS avant et après le filtrage homomorphique.

En dépit de la diminution de la distance de khi deux on obtient toujours une valeur de p -valeur nulle et donc on rejette l'hypothèse de normalité.

A.2.5 Test de Cramer

Le test de Cramer-Von Mises présente les mêmes applications que celles du test de Kolmogorov. La différence entre ces deux tests réside dans le fait que pour le test de

Kolmogorov seul l'écart maximum entre la distribution empirique et la distribution d'ajustement entre en considération. En effet, pour le test de Cramer, la distance entre les deux fonctions de répartition empiriques est évaluée par la somme des carrés de leur écarts. D'une autre part, le test de Kolmogorov est beaucoup plus sensible à l'existence des points aberrants dans un échantillon comparé au test de Cramer-Von Mises.

L'implémentation de test de Cramer pour le cas de notre image SAS est encore réalisée en suivant le même procès. C'est-à-dire pour la même valeur de risque $\alpha = 5\%$ nous supposons que :

- L'hypothèse nulle H_0 : la distribution de l'image est normale avec une valeur de la moyenne $\mu = 0$ et un écart type $\delta = 1$;
- L'hypothèse alternative H_1 : la distribution de l'image n'est pas normale avec une valeur de $\mu = 0$ et $\delta = 1$;

La valeur de critère de Smirnov-Cramer-Von obtenue pour l'image initiale est $CV = 8,2808e - 006$.

Suite à l'application du filtre homomorphique dans les conditions de base, on obtient une valeur de CV un peu plus faible et égale à $7.4522e-004$. Cependant on a toujours une valeur de H égale à 1 impliquant le rejet de l'hypothèse H_0 pour le risque de 5%.

A.3 Modèle probabiliste de présence des objets d'intérêt

Dans cette partie, nous calculons les paramètres de droites affines des courbes de variation de paramètre λ estimé en fonction du pourcentage d'occupation des objets dans l'image SAS. Une méthode de régression linéaire d'ordre 1 donne une bonne estimation de ces paramètres.

Dans la suite, la définition de la droite moyenne de régression permet de conclure sur l'évolution de paramètre λ pour les trois distributions testées (loi gaussienne, loi de Rayleigh et loi de Weibull). Dans la deuxième partie de ce travail, nous réalisons un test d'hypothèse statistique de valeur de risque α pour identifier les images contenant ou pas des objets. Ensuite, nous appliquons une stratification de niveau 5% et 95% pour identifier les images de forte, moyenne ou faible probabilité de présence des objets.

A.3.1 Régression Linéaire

Dans ce travail, nous testons la méthode de la régression linéaire sur l'ensemble des courbes d'évolution de pourcentage d'occupation des objets dans l'image en fonction de λ estimé. Nous considérons respectivement la loi normale, la loi de Rayleigh et la loi de Weibull. Les illustrations de ces résultats ainsi que les courbes d'estimation correspondantes sont présentés dans la figure A.1.

L'ensemble des images de test utilisées pour le traçage de ces courbes sont synthétisées en considérant les mêmes propriétés statistiques de l'image SAS de test. Ces propriétés ont été détaillées dans le paragraphe 3.4.2.

Suite à une étude comparative des méthodes d'estimation, nous supposons que l'utilisation de la méthode de régression linéaire d'ordre 1 permet d'obtenir une bonne estimation de paramètres des courbes d'évolution de λ . Les expressions de ces droites pour le cas de la loi normale, la loi de Rayleigh et la loi de Weibull sont respectivement les suivantes :

$$P1 = 0.696 \cdot \lambda - 0.661 \quad (\text{A.2})$$

$$P2 = 0.727 \cdot \lambda - 0.725 \quad (\text{A.3})$$

$$P3 = 0.996 \cdot \lambda - 0.809 \quad (\text{A.4})$$

Dans la suite de ce travail, nous calculons la droite de régression moyenne pour les trois lois de distributions.

L'application de la méthode de régression d'ordre 1 sur la moyenne des résultats obtenus, pour les différents tests de synthèses réalisés, permet de retrouver la fonction suivante (fonction de la droite de régression moyenne) :

$$Pmoy = 0.704 \cdot \lambda - 0.597 \quad (\text{A.5})$$

La figure A.2 présente le résultat d'estimation de la droite d'évolution moyenne de λ en fonction de pourcentage d'occupation des objets pour l'ensemble des images de test. Arrivés à ce stade, nous cherchons à définir une grandeur probabiliste nous permettant de juger l'occupation ou non de l'image de synthèse par des événements rares ($\% < 1$) en se basant sur la valeur de λ estimée.

En s'appuyant sur les résultats précédemment trouvés, nous admettons un test d'hypothèse statistique pour une valeur de risque initialement fixé à 5% (choix arbitraire).

Ainsi, nous définissons deux classes : classe absence et classe présence d'événements rares que selon la valeur de α on peut y attribuer une carte de probabilité (probabilité de présence faible, moyenne ou forte).

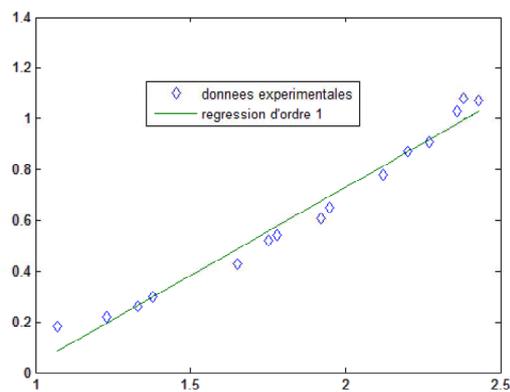
Selon la courbe de la figure A.2 et l'hypothèse de classification, on conclut que pour un pourcentage d'occupation $< 5\%$ (correspondant à une valeur de $\lambda < 0.912$), l'image de test présente un pourcentage nul du présence des objets d'intérêt. Et, pour une valeur de $\lambda \geq 0.912$, on conclut la présence des objets dans l'image. En appliquant notre adéquation à 5% et 95% nous identifions alors les images à faible, moyenne ou forte probabilité de présence des objets.

A.4 Conclusions

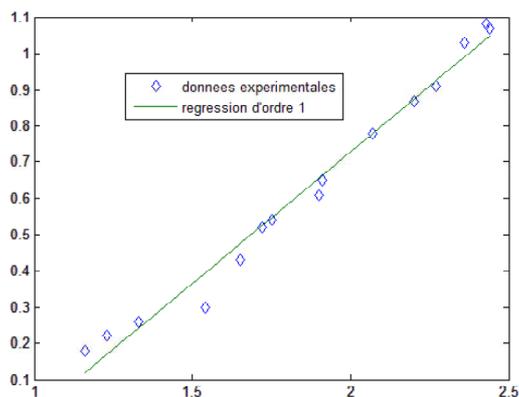
Dans ce chapitre, nous avons utilisé les tests d'hypothèses pour pour deux différents objectifs.

Dans la première partie de ce chapitre, les tests d'hypothèses contribuent à l'identification du modèle statistique le plus adéquat à l'image suite à son filtrage homomorphique. Malgré l'obtention d'une valeur de H_0 nulle, pour la plupart des tests réalisés, le calcul de la distance dans chaque test permet de juger l'adéquation avec le modèle théorique. Néanmoins, une étude de sources de ce rejet s'avère nécessaire.

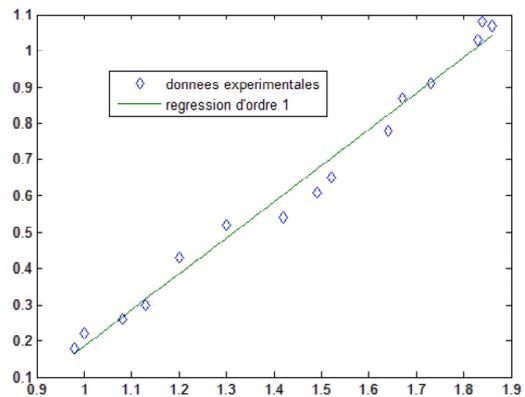
Dans la deuxième partie, l'application des tests d'hypothèses sur la courbe moyenne d'estimation de la variation de λ , contribue à la détermination d'une façon automatique et avec une précision de 95% si l'image contient des objets ou non. Ce résultat est considéré intéressant pour la mise en place d'un processus automatique et rapide de détection des objets d'intérêt.



(a) Loi normale



(b) Loi de Rayleigh



(c) Loi de Weibull

Figure A.1: Estimation de la droite de variation de paramètre λ en fonction de pourcentage d'occupation des objets dans l'image.

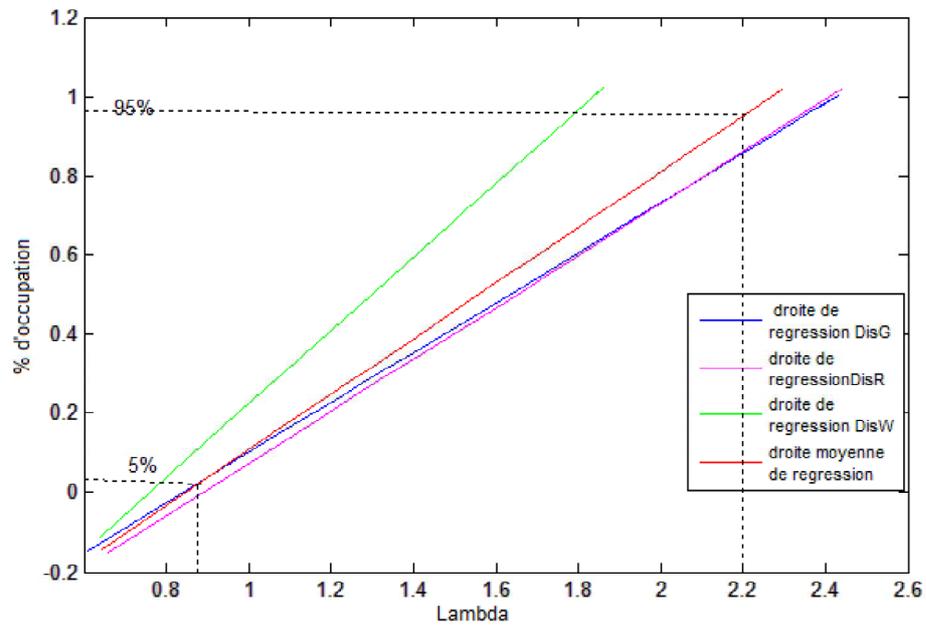


Figure A.2: Droite de régression moyenne estimant la variation du paramètre de la sigmoïde en fonction du pourcentage d'occupation des images par des objets d'intérêt.

La fusion de données

B.1 Introduction

La fusion d'informations permet la gestion des quantités très importantes de données multi-sources.

Les méthodes de fusion sont employées dans les domaines de traitement des images tels que la reconnaissance, l'identification, la détection des objets, etc. Les principales méthodes de fusion d'informations sont issues essentiellement des probabilités (les approches bayésiennes) et les approches floues (théorie des possibilités).

B.2 Les différentes approches de fusion

Différentes approches sont considérées comme méthodes de fusion d'informations parmi les quelles : les filtres de Kalman, les réseaux de neurones, ou encore des méthodes d'extraction d'informations telles que les algorithmes génétiques et les réseaux bayésiens. Les classifieurs peuvent être aussi vus comme des approches de fusion : les machines à vecteurs de support (SVM), les chaînes de Markov cachées, etc. Néanmoins, pour toutes les méthodes de fusion quatre étapes sont définies. La modélisation est la première étape de fusion et elle consiste au choix de la manière de la représentation des informations à fusionner : une distribution, une fonction de coût, une formule, etc.

On distingue deux types d'information : information de type numérique et information de type symbolique. L'information numérique est exprimée sous forme de nombre Il peut s'agir de l'intensité du signal, de niveaux de gris, de temps, etc . L'information symbolique est information pouvant s'exprimer sous forme de symboles, de propositions, de règles d'associations, etc. La seconde étape est l'estimation. L'estimation est souvent dépendante de la modélisation par exemple : l'estimation pour les distributions.

La combinaison est la troisième étape de la procédure de fusion. C'est la phase de regroupement des informations. Il s'agit ici de choisir un opérateur adapté au formalisme de la modélisation. D'une manière générale les opérateurs de combinaison fournissent un résultat de même nature que les informations combinées. La dernière étape de la fusion d'informations est la décision. la combinaison est réalisée en vue d'améliorer la prise de décision. D'une manière générale, il s'agit ici de minimiser ou de la maximiser une fonction issue de la combinaison.

B.3 La fusion globale

La fusion globale permet de considérer toutes les informations lors de la fusion. Afin de simplifier la fusion globale une première approche consiste à prendre une décision locale pour chaque source prise indépendamment. Ces décisions sont ensuite combinées pour finalement établir la décision finale : c'est l'approche de fusion de décisions. Les désavantages de cette approche est qu'elle ne tiennent pas en compte les relations de dépendances et corrélations entre les sources.

La deuxième approche consiste à combiner les informations des différentes sources pour une décision de donnée. Cette méthode permet de respecter la relation de dépendance entre les sources mais exige la présence simultanée de toutes les informations.

B.4 Imperfections de l'information

Les principales imperfections considérées sont l'incertitude, l'imprécision, l'incomplétude, la redondance, la complémentarité, le conflit et l'ambiguïté.

L'incertitude de l'information est l'imperfection la plus étudiée. Elle caractérise le degré de conformité à la réalité d'une information. D'une manière générale, une information incertaine décrit une connaissance partielle de la réalité, alors que le certain entraîne nécessairement la connaissance de toute la réalité. Les approches probabilistes permettent de modéliser l'incertitude parfaitement.

L'imprécision d'une information mesure un défaut quantitatif de connaissance. Ce défaut, est étudié dans la théorie des sous-ensembles flous, la théorie des possibilités ou la théorie des croyances. L'imprécision est donc un défaut quantitatif de la connaissance, alors que l'incertitude est un défaut qualitatif de la connaissance.

L'incomplétude est le manque d'information apporté par la source. Elle peut se mesurer par la différence de la quantité d'information réellement fournie par la source et de la quantité d'information que la source doit fournir. L'entropie de Shannon est souvent utilisé pour mesurer la quantité d'information.

La redondance d'informations ou de sources est le fait d'avoir plusieurs fois la même information. Cette quantité peut être calculée en considérant la quantité d'information de ces sources. D'autre part, des sources ou des informations sont dites complémentaires si elles sont de nature différente et permettent de préciser la réponse du système.

La complémentarité des informations d'une source par rapport à une autre peut se mesurer à partir d'une mesure de la quantité d'informations d'une source. Et, deux informations ou plus sont considérées en conflit si elles sont contradictoires. Finalement, l'ambiguïté d'une information est le fait que celle-ci entraîne deux ou plus interprétations.

B.5 Méthodes de la fusion

Différentes approches de fusion développées varient selon leur prise en compte ou non des différentes imperfections précédemment citées. Parmi les méthodes de la fusion exploitées dans les différents travaux on note les méthodes de vote, l'approche bayésienne et la théorie des croyances. Ces différentes méthodes sont introduites en présentant pour chaque approche ses étapes de la fusion : modélisation, estimation, combinaison et la prise de la décision.

B.5.1 Méthodes du vote

La méthode de vote est considérée la méthode de fusion d'informations la plus simple à mettre en œuvre. L'intérêt de cette approche est qu'elle ne nécessite pas de connaissances a priori. De l'autre côté, le principe du vote est aussi considéré comme une méthode de combinaison particulièrement adaptée aux décisions.

La règle du vote majoritaire consiste à choisir la décision prise par le maximum de sources, La règle la plus employée est la règle du vote majoritaire absolu. L'étape de modélisation consiste à appliquer la fonction suivante :

$$M_j^i(x) = \begin{cases} 1 & \text{si } S_j(x) = i \\ 0 & \text{sinon} \end{cases} \quad (\text{B.1})$$

avec S_j est la source j et M_j^i est la modélisation de l'information x obtenue par la j ème source pour la décision i . Cette règle ne peut être considérée que dans le cas où les sources sont supposées de performances identiques. Néanmoins, elle ne permet en aucun cas de prendre en compte des imperfections des données.

Ainsi, la règle de vote absolue est encore améliorée par l'idée de pondérer les réponses de chaque source. La combinaison est alors exprimée par la formule suivante :

$$M_k^E(x) = \sum_j^m (\alpha_{jk} \cdot M_k^j(x)) \quad (\text{B.2})$$

Pour une combinaison s'exprimant sous la forme d'une somme pondérée, la décision est exprimée par l'équation suivante :

$$E(x) = \begin{cases} k & \text{si } \max_k(M_k^E(x)) > \frac{m}{2} \\ k + 1 & \text{sinon.} \end{cases} \quad (\text{B.3})$$

D'autres règles de décision sont obtenues en introduisant les opérateurs logiques à la règle de vote majoritaire.

B.5.2 L'approche bayésienne

L'approche bayésienne repose sur la théorie des probabilités. Pour un x de l'ensemble des informations provenant de la source j , la modélisation est exprimée en fonction de la probabilité conditionnelle par la formule suivante :

$$M_j^i(x) = p(d_i \setminus S_j) \quad (\text{B.4})$$

L'étape d'estimation est indispensable étant donné que la modélisation fait intervenir des distributions de probabilités. Dans le cas discret, la formule de Bayes est utilisée pour l'estimation (calcul du terme $p(d_i \setminus S_j)$) et dans le cas continu, l'estimation est réalisée en approchant la fonction de modélisation à des approches connues (l'approche gaussienne surtout).

Ainsi, selon le cas (continu ou discret), deux types de combinaison peuvent être employés : la combinaison bayésienne et la combinaison des probabilités.

La combinaison bayésienne consiste à déterminer les probabilités $p(d_i \setminus S_j \dots S_m)$ (application directe de la modélisation de Bayes), alors que l'approche de la combinaison des probabilités permet de considérer le résultat de chaque source j puis de combiner ces probabilités afin d'avoir la probabilité globale d'obtenir une décision d_i .

Concernant l'étape de décision des nombreux critères de décisions sont envisageables : maximum a posteriori, L'espérance maximale, Le maximum de vraisemblance, Le maximum d'entropie, etc.

B.5.3 La théorie des croyances

La théorie des croyances est plus adaptée à des problèmes de classification que des problèmes d'estimation. Cette méthode repose sur la modélisation à partir de fonctions de masse permettant une bonne représentation des connaissances. Le principe de la modélisation de la théorie de croissance se base sur les fonctions de masse. L'espace des fonctions de masse m est donné par l'ensemble de toutes les disjonctions possibles des décisions d_i . La fonction de masse m_j (donnée par la source j) vérifie en général la propriété suivante :

$$\sum_{A \in 2^D} m_j(A) = 1 \quad (\text{B.5})$$

avec D est l'ensemble de toutes les intersections possibles entre les décisions possibles et A est un ensemble de D . La fonction de masse $m_j(A)$ caractérise le degré de croyance en la proposition A donnée par la source S_j .

Une fonction de modélisation permet d'affecter toute la masse d'une source S_j à un sous-ensemble non-vide A de 2^D selon la formule suivante : (avec A et B deux ensembles de décision exclusifs) :

$$E(x) = \begin{cases} m_j(A) = s \\ m_j(D) = 1 - s \\ m_j(B) = 0 \end{cases} \quad B \in 2^D, B \neq A \text{ et } B \neq D. \quad (\text{B.6})$$

Plusieurs modes de combinaison ont été développés dans le cadre de la théorie des croyances. Il existe principalement deux types de combinaison : la combinaison conjonctive et la combinaison disjonctive.

La combinaison conjonctive permet de combiner les fonctions de masse en considérant les intersections des éléments et la combinaison disjonctive est donnée non plus en considérant les intersections, mais aussi les unions des ensembles de décision. Le choix de la décision d_i , ou d'une disjonction se fait d'une manière générale par la maximisation d'un critère donné.

B.6 Conclusions

Les mesures des imperfections de l'information utilisent souvent la notion de la mesure de la quantité d'information. L'entropie de Shannon est souvent employée pour cette mesure. D'autre part, Les informations supplémentaires permettent de compléter les informations issues des capteurs. Elles concernent les sources (leur dépendance, leur fiabilité), ou le domaine de l'application. Ces informations supplémentaires peuvent aider à la modélisation, l'estimation, la combinaison ou la décision de la fusion et nécessitent leur formalisation avant utilisation. Ainsi, les différentes approches de fusion sont aussi utilisées dans le cadre de la fusion des données supplémentaires.

Liste de mes publications

Conférences internationales avec actes et comité de lecture

- [1] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. Sonar Image Preprocessing Method based on Homomorphic Filtering. *MTS/IEEE Oceans 2012 Hampton Roads*, 14-19 october 2012.
- [2] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. On the Use of Statistical Tests on Homomorphic Filtered SAS Images. *Oceans 2013 : proceedings of the MTS/IEEE Bergen Conference, Piscataway, NJ, USA : IEEE*, Bergen, Norway, 10-13 june 2013, 2013.
- [3] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. A new Segmentation Approach for Unimodal Image Histograms: Application to the Detection of Regions of Interest in Sonar Images. *MTS/IEEE Oceans 2014*, St-Johns, Canada, 2014.
- [4] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. Rare Events Detection Algorithm: Application to Sonar Image. *MTS/IEEE Oceans 2014*, St-Johns, Canada, 2014.

Conférences francophones et nationales avec actes et comité de lecture

- [5] I. Mandhouj, H. Amiri, F. Maussang et B. Solaiman. Sonar image processing for underwater object detection based on high resolution system. *Signal and Document Processing Workshop (SIDOP 2012)*, Mars 2012.
- [6] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. Modélisation statistique d'une image Sonar après filtrage homomorphique. *GRETSI 2013 : 24ème colloque du Groupement de Recherche en Traitement du Signal et des Images*, 03-06 septembre 2013, Brest, France, 2013.
- [7] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. Description et détection automatique des objets rares dans une image unimodale. 5^{me} édition des ateliers Représentation des Formes et des Mouvements à partir des données Images (RFMI'15) Images (RFMI'15) (article accepté).

Articles soumis à des revues internationales avec comité de lecture

- [8] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. A method for automatic detection of objects in a unimodal image, soumis à *Elsevier Pattern Recognition*, *accepté avec corrections mineures*.
- [9] I. Mandhouj, F. Maussang, B. Solaiman et H. Amiri. A New Algorithm to detect Aberrant Object in Unimodal Histogram Images, soumis à *IEEE Communications Letters*, *en cours de révisions*.

Bibliographie

- [AAR04] S. AGARWAL, A. AWAN et D. ROTH : Learning to detect objects in images via a sparse, part-based representation. *IEEE Trans. on Pattern Analysis and Machine Intelligence.*, 26(11):1475–1490, 2004. (cité dans la page 17.)
- [ABMA01] D.W. AHA, L.A. BRESLOW et H. MUÑOZ-AVILA : Conversational case-based reasoning. *Applied Intelligence*, 14:9–32, 2001. (cité dans la page 140.)
- [Abu89] A. S. ABUTALEB : Automatic thresholding of graylevel pictures using two-dimensional entropy. *Computer Vision, Graphics, and Image Processing*, 47:22–32, 1989. (cités dans les pages 59 et 67.)
- [AL04] D. A. ABRAHAM et A. P. LYONS : Faint object classification and analysis systemguest editorial : non-rayleigh reverberation and clutter. *IEEE Journal of Oceanic Engineering*, 29(2):193–196, 2004. (cité dans la page 45.)
- [AMP84] Y. S. ABU-MOSTAFA et D. PSALTIS : Recognitive aspects of moment invariants. *Pattern Analysis and Machine Intelligence, IEEE Transactions*, pages 698–706, 1984. (cité dans la page 98.)
- [AR78] N. AHUJA et A. ROSENFELD : A note on the use of second order gray-level statistics for thershold selection. *IEEE Trans Syst.Man Cybern*, pages 895–898, 1978. (cité dans la page 62.)
- [BAB⁺03] R. BERGMANN, K.-D. ALTHOFF, S. BREEN, M. GOKER, M. MANAGO, R. TRAPHONER et S. WESS : Developing industrial case-based reasoning applications: The inreca methodology. *LNAI 1612. Springer*, 2, 2003. (cité dans la page 139.)
- [BDJ94] B.E.COOPER, D.L.CHENOWETH et J.E.SELVAGE : Fractal error for detecting man-made features in aerial images. *Electronics Letters*, pages 554–555, 1994. (cité dans la page 15.)
- [BDMV95] Ch. BARRATTE, J.E. DALPHOND, P. J. MANGIN et J. L. VALADE : An automatic determination of threshold for the image analysis of prints. *In Advances in Printing Science and Technology: Proceedings of the 23rd Research Conference of IARIGAI, Paris*, 26(10):451–459, 1995. (cités dans les pages 61 et 62.)
- [Bel08] G. Van BELLE : *Statistical Rules of Thumb*. J. Wiley and Sons, Hoboken, NJ., second edn édition, 2008. (cité dans la page 9.)
- [Bez81] J. C. BEZDEK. : *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press, New York, 1981. (cité dans la page 102.)

- [BGG09] M. D. BREITENSTEIN, H. GRABNER et L. V. GOOL : Hunting nessesie: real-time abnormality detection from webcams. *In IEEE International Workshop on Visual Surveillance*, 2009. (cité dans la page 9.)
- [BQJM06] S. BAZEILLE, I. QUIDU, L. JAULIN et J.-P. MALKASSE : Automatic underwater image denoising. *In CMM'06*, 2006. (cité dans la page 37.)
- [Bru87] B. BRUMBACK : A chi-square test for fault-detection in kalman filters. *IEEE Transactions on Automatic Control*, 1987. (cité dans la page 47.)
- [Bur01] Michael C. BURL : *Data Mining for Scientific and Engineering Applications*. Springer US, 2001. (cité dans la page 20.)
- [BW07] B.YASICI et W.YOLACAN : A comparison of various tests of normality. *Journal of statistical Computation and Simulation*, 77:175–183, 2007. (cité dans la page 50.)
- [BZ09] P. BIAN et L. ZHANG : Biological plausibility of spectral domain approach for spatiotemporal visual saliency. *Springer-Verlag Berlin, Heidelberg*, pages 251—258, 2009. (cité dans la page 113.)
- [Car96] M. J. CARLOTTO : Detecting man-made features in sar imagery. *Geoscience and Remote Sensing Symposium, IGARSS '96*, 1:27–31, May 1996. (cité dans la page 16.)
- [CBT02] F. CUPILLARD, F. BRÉMOND et M. THONNAT. : Group behavior recognition with multiple cameras. *WACV*, 2002. (cité dans la page 95.)
- [CCJ11] F. CAI, H. CHEN et Ma. JIANWEI : Man-made object detection based on texture clustering and geometric structure feature extracting. *Information Technology and Computer Science*, 2:9–16, March, 2011. (cité dans la page 89.)
- [CCM11] Fei CAI, Honghui CHEN et Jianwei MA : Man-made object detection based on texture clustering and geometric structure feature extracting. *International Journal of Information Technology and Computer Science(IJITCS)*, 3(2), March 2011. (cité dans la page 16.)
- [CCMA15] C.MEILLIER, F. CHATELAIN, O. MICHEL et H. AYASSO : Contrôle des erreurs pour la détection d'événements rares et faibles dans des champs de données massifs. *GRETSI, Sep 2015, Lyon, France*, 2015. (cité dans la page 131.)
- [CdFB04] P. CARBONETTO, N. de FREITAS et K. BARNARD : A statistical model for general contextual object recognition. *Proc. European*

- Conf. Computer Vision*, pages 350–362, 2004. (cité dans la page 17.)
- [CHE00] Ch. CHESNAUD : *Techniques statistiques de segmentation par contour actif et mise en œuvre rapide*. Thèse de doctorat, Ecole nationale supérieure de physique de Marseille, 2000. (cité dans la page 58.)
- [CMV02] Y. CARON, P. MAKRIS et N. VINCENT : A method for detecting artificial objects in natural environments. *Pattern Recognition, Proceedings. 16th International Conference*, 1:600–603, 2002. (cités dans les pages 16 et 91.)
- [CS90] M. J. CARLOTTO et M. C. STEIN : A method for searching artificial objects on planetary surfaces. *Journal of the British Interplanetary Society*, 43, 1990. (cité dans la page 15.)
- [CYZ05a] G. CAO, X. YANG et M. ZHIHONG : A method for detecting artificial objects in natural environments. *Computer Vision and Pattern Recognition CVPR*, 1:474–479, 2005. (cité dans la page 92.)
- [CYZ05b] G. CAO, Xi. YANG et M. ZHIHONG : A two-stage level set evolution scheme for man-made objects detection in aerial images. *Computer Vision and Pattern Recognition CVPR*, 1:474 – 479, June 2005. (cité dans la page 15.)
- [DRW79] L.S. DAVIS, A. ROSENFELD et J.S. WESZERKA : Region extraction by averaging and thresholding. *IEEE Trans.Syst, Man Cybern SMC-9*, 1979. (cités dans les pages 15 et 62.)
- [DS03] Gy. DORKO et C. SCHMID : Selection of scale-invariant parts for object class recognition. *In Proc. International Conference on Computer Vision*, page 634–640, 2003. (cité dans la page 17.)
- [Dun73] J. C. DUNN : A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, 3:32–57, 1973. (cité dans la page 102.)
- [EPSJ98] E.NETTER, P.TROUFLEAU, S.STINES et J.CARCINOME : canalaire in situ du sein: place de l'imagerie. *J Radiol*, 79:651–658, 1998. (cité dans la page 131.)
- [FLL⁺12] Y. FANG, W. LIN, B.-S. LEE, C.-T. LAU, Z. CHEN et C.-W. LIN : Bottom-up saliency detection model based on human visual sensitivity and amplitude spectrum. *Multimedia, IEEE Transactions*, 14:187—198, 2012. (cité dans la page 113.)
- [FM92] J. FRANKE et E. MANDLER : A comparison of two approaches for combining the votes of cooperating classifiers. *Proc. 11th Int.*

- Conf. Pattern Recognition, The Hague, The Netherlands*, 2:611–614, 1992. (cité dans la page 105.)
- [FMR08] P. FELZENSZWALB, D. MCALLESTER et D. RAMANAN : A discriminatively trained, multiscale, deformable part model. *In CVPR*, 2008. (cité dans la page 17.)
- [FMRT97] G.L. FORESTI, V. MURINO, C.S. REGAZZONI et A. TRUCCO : A voting-based approach for fast object recognition in underwater acoustic images. *In IEEE Journal of Oceanic Engineering*, 22(1): 57–65, janvier 1997. (cité dans la page 16.)
- [For97] P.E. FORSSÉN : *Detection of Man-made Objects in Satellite Images*. Thèse de doctorat, Linköpings University-Depart. of Electrical Engineering Computer Vision, 1997. (cité dans la page 15.)
- [FPSSU96] U. M. FAYYAD, G. PIATETSKY-SHAPIRO, P. SMYTH et R. UTHURUSAMY : *Advances in knowledge discovery and data mining*. AAAI Press P. Smyth Menlo Park, 1996. (cité dans la page 18.)
- [FR98] C. FRALEY et A.E. RAFTERY : How many clusters? which clustering method? answers via model-based cluster analysis. *Technical Report No. 329., Department of Statistics University of Washington*, 1998. (cité dans la page 95.)
- [GC84] M. Le GAL et G. CHAVANNE. : Valeur diagnostique des microcalcifications groupées découvertes par mammographie. *Bull Cancer*, 71:57–64, 1984. (cité dans la page 122.)
- [GH98] P. T. GOUGH et D. W. HAWKINS : A short history of synthetic aperture sonar. *in Proc. IEEE Int. Geosci. Remote Sens. Sump, Seattle, WA*, page 618–620, 1998. (cité dans la page 36.)
- [GMZ09] C. GUO, Q. MA et L. ZHANG. : Spatio-temporal saliency detection using phase spectrum of quaternion fourier transform. *Proc. IEEE Computer Vision and Pattern Recognition*, 2009. (cité dans la page 113.)
- [GRT93] A. GRAD, M. ROSSELLI et Del TURCO : Breast cancer screening in europe. *Springer Verlag*, 1993. (cité dans la page 121.)
- [Gru95] T. R. GRUBER : Toward principles for the design of ontologies used for knowledge sharing. *In International Journal of human Computer Studies*, volume 43, pages 907–928, 1995. (cité dans la page 23.)
- [GW07] R. GONZALEZ et R. WOODS. : *Digital Image Processing*. 3rd ed. Englewood Cliffs, 2007. (cité dans la page 31.)

- [HAB08] C. HUDELLOT, J. ATIF et I. BLOCH : Fuzzy spatial relation ontology for image interpretation. *Fuzzy Sets and Systems archive*, 159:1929–1951, August 2008. (cité dans la page 23.)
- [Haw80] D. HAWKINS : *Identification of Outliers*. Chapman and Hall, 1980. (cité dans la page 9.)
- [Her09] J.F. HERON. : La mammographie. *cours en ligne, Faculté de Médecine de Caen France.*, 2009. (cité dans la page 122.)
- [HG99] M. P. HAYES et P. T. GOUGH : Using synthetic aperture sonar for mine detection. *in Proc. Austral.-Amer. Joint Conf. Technol. Mines Mine Countermeas. Syst., Sydney, Australia*, 1:1–10, 1999. (cité dans la page 36.)
- [HG04] M. P. HAYES et P. T. GOUGH : Synthetic aperture sonar : A maturing discipline. *In Proc. 7th Eur. Conf. Underwater Acoust*, 30:1101—1106, July 2004. (cité dans la page 36.)
- [HHN06] Z. HOU, Q. HU et W. L. NOWINSKI : On minimum variance thresholding. *Pattern Recognition Letters*, pages 1732–1743, 2006. (cités dans les pages 16, 63, 113 et 114.)
- [HHP09] S. HASSAN, F. HÉTROUY et O. PALOMBI : Segmentation de mailages guidée par une ontologie. *AFIG 2009, 22e Journées de l'Association Française d'Informatique Graphique.*, 2009. (cité dans la page 23.)
- [HJB⁺05] R. HAMID, A. JOHNSON, S. BATTA, A. BOBICK, C. ISBELL et G. COLEMAN : Detection and explanation of anomalous activities - representing activities as bags of event n-grams. *In IEEE Conference on Computer Vision and Pattern Recognition*, pages 1031–1038, 2005. (cités dans les pages 9 et 96.)
- [HK06] J. HAN et M. KAMBER. : *Data Mining: Concepts and Techniques*. Rajkamal Electric Press, 2006. (cités dans les pages 19 et 20.)
- [HKSD97] H. Sylvia HEYWANG-KOBRUNNER, I. SCHREER et D. David DER-SHAW : *Diagnostic breast imaging : mammography, sonography, magnetic resonance imaging, and interventional procedures*. Georg Thieme, Germany, 1997. (cité dans la page 121.)
- [HLES06] J. S. HARE, P. H. LEWIS, P. G. ENSER et C. J. SANDOM : Mind the gap: another look at the problem of the semantic gap in image retrieval. *In Electronic Imaging 2006. International Society for Optics and Photonics*, page 309–607, 2006. (cités dans les pages 22 et 23.)

- [HSMP01] B. HEISELE, T. SERRE, S. MUKHERJEE et T. POGGIO : Feature reduction and hierarchy of classifiers for fast object detection in video images. *In Proc. IEEE Conf. Computer Vision and Pattern Recognition*, 30:893–908, 2001. (cité dans la page 17.)
- [htt] [HTTP://PEIPA.ESEX.AC.UK/INFO/MIAS.HTML](http://peipa.essex.ac.uk/info/mias.html). : [visité le 12/12/2014]. (cité dans la page 123.)
- [ILF13] N. IMAMOGLU, W. LIN et Y. FANG : A saliency detection model using low-level features based on wavelet transform. *Multimedia, IEEE Transactions*, 15:96–105, 2013. (cité dans la page 113.)
- [Ish92] M. ISHIZUKA : Hypothetical reasoning. *Jpn.J.Fuzzy Theory Syst*, 4:483–495, 1992. (cité dans la page 99.)
- [JT81] J.F.JARVIS et J.A. TYSON : Faint object classification and analysis system. *in The Astronomical Journal*, 86:476–495, 1981. (cité dans la page 131.)
- [JW95] D.J. JOBSON et G.A. WOODSELL : Properties of a center/surround retinex. *Surround design. NASA Technical Memorandum*, page 15, 1995. (cité dans la page 30.)
- [KH03a] S. KUMAR et M. HEBERT : Discriminative random fields: A discriminative framework for contextual interaction in classification. *IEEE Int. Conf. on Computer Vision*, 2:1150 – 1157, 2003. (cité dans la page 16.)
- [KH03b] S. KUMAR et M. HEBERT : Man-made structure detection in natural images using a causal multiscale random field. *Computer Vision and Pattern Recognition, IEEE Computer Society Conference*, 1:119–126, 2003. (cité dans la page 90.)
- [KKH01] J.Y. KIM, L.S. KIM et S.H. HWANG : An advanced contrast enhancement using partially overlapped sub-block histogram equalization. *Circuits and Systems for Video Technology, IEEE Transactions*, 11(4):475–484, 2001. (cité dans la page 30.)
- [Kla00] A. KLAUTAU : Multiplicative homomorphic processing and its application to image enhancement. <http://speech.ucsd.edu/aldebaro>, page 1, March 2000. (cité dans la page 34.)
- [KSBD07] I. KARASALO, P. SKOGQVIST, Ph. BLONDEL et P.F. DOBBINS : Buried waste inspection: Acoustical images and inversion from multiple-aspect scattering. *Buried Waste Inspection: Acoustical Images And Inversion From Multiple-Aspect Scattering*, pages 115–126, 2007. (cité dans la page 36.)

- [KSW85] J. N. KAPUR, P. K. SAHOO et A. K. C. WONG : A new method for gray-level picture thresholding using the entropy of the histogram. *Graph. Models Image Process.* 29, pages 273—285, 1985. (cités dans les pages 67 et 68.)
- [KU85] C. KOCH et S. ULLMAN : Shifts in selective visual attention : Towards the underlying neuronal circuitry. *Human Neurobiology*, 4, 1985. (cité dans la page 111.)
- [LA98] M. LENZ et K. ASHLEY : *Proceedings of the AAAI98 Workshop on Textual Case-Based Reasoning*. AAAI Press, 1998. (cité dans la page 140.)
- [Lan86] M. LANYI : Diagnosis and differential diagnosis of breast calcifications. *Springer Verlag*, 1986. (cité dans la page 121.)
- [LCC01] P.S. LIAO, T.S. CHEN et P.C. CHUNG : A fast algorithm for multilevel thresholding. *Journal of Information Science and Engineering* 17., 2001. (cité dans la page 68.)
- [LCN98] L.ITTI, C.KOCH et E. NIEBUR : A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on Pattern Analysis and Intelligence*, 20(11):1254–1259, 1998. (cités dans les pages 111 et 113.)
- [Lea96] David B. LEAKE : *case-Based Reasoning: Experiences, Lessons, and Future Directions*. AAAI Press/MIT Press, Menlo Park, CA, 1996. (cité dans la page 135.)
- [Lee81] J. S. LEE : Speckle analysis and smoothing of synthetic aperture radar images. *Computer Graphics and Image Processing*, 17:24–32, 1981. (cité dans la page 29.)
- [LHWH06] C. K. LEE, M. F. HO, W. S. WEN et C. L. HUANG : Abnormal event detection in video using n-cut clustering. *International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, pages 407—410, 2006. (cité dans la page 96.)
- [LL94] Chi-Kin LEUNG et Fuet-Kit LAM : Image segmentation using maximum entropy method. *Image Processing and Neural Networks*, pages 29–32, 1994. (cité dans la page 67.)
- [LLB⁺00] I. LEICHTER, R. LEDERMAN, S. BUCHBINDER, P. BAMBERGER, B.NOVAK et S. FIELDS. : Optimizing parameters for computer-aided diagnosis of microcalcifications at mammography. *Computerized Medical Imaging and Graphics*, 7(6):1406—12, 2000. (cité dans la page 126.)

- [LLFZ03] M. LEGRIS, K. LEBART, F. FOHANNON et B. ZERR : Les capteurs d'imagerie en robotique sous-marine: Tendances actuelles et futures. *Traitement du Signal*, 20:137–164, 2003. (cité dans la page 36.)
- [LLL06] J. LI, X. LIU et H. LI : Extraction of texture feature landuse information and identification method of from spot5 image. *Journal of Remote Sensing*, 10:926–932, 2006. (cité dans la page 16.)
- [LS93] D.S. LEE et S. N. SRIHARI : Handprinted digit recognition: a comparison of algorithms. *Proc. 3rd Int. Workshop Frontiers Handwriting Recognition*, pages 153—162., May, 1993. (cité dans la page 105.)
- [Lur02] X. LURTON : Eléments d'analyse des systèmes acoustiques sous-marins. *ENSIETA, Brest, France*, 2002. (cité dans la page 36.)
- [LZLM07] Y. LIU, D. ZHANG, G. LU et W.-Y. MA : A survey of content-based image retrieval with high-level semantics. *Pattern Recognition*, 40:262–282, 2007. (cités dans les pages 22 et 23.)
- [MA84] D.M. MARK et P.B. ARONSON : Scale-dependent fractal dimensions of topographic surfaces : an empirical investigation with applications in geomorphology and computer mapping. *Journal of the International Association for Mathematical Geology*, 16(7):671–683, octobre 1984. (cité dans la page 15.)
- [Man82] Benoit B. MANDELBROT : *The fractal Geometry of Nature*. W.H. Freeman and Company, San Francisco, 1982. (cité dans la page 15.)
- [M.C83] M.CREUTZ : Microcanonical monte carlo simulation. *Phy. Rev. Letters*, 50 (19):1411–1414, 1983. (cité dans la page 59.)
- [MCH03] F. MAUSSANG, J. CHANUSSOT et A. HÉTET : Segmentation automatique d'images sonar à antenne synthétique pour la détection d'échos de mines sous-marines. *19e colloque GRETSI*, septembre, 2003. (cité dans la page 37.)
- [MCMCFGCP05] M.R. MEDINA-CARNICER, F.J. MADRID-CUEVAS, N.L. FERNANDEZ-GARCA et A. CARMONA-POYATO : Evaluation of global thresholding techniques in non-contextual edge detection. *Pattern Recognition Letters*, 26(10):1423–1434, 2005. (cités dans les pages 61 et 67.)
- [MDK⁺98] A. MARTIN, G. DODDINGTON, T. KAMM, M. ORDOWSKI et M. PRZYBOCKI. : The det curve in assessment of detection task performance. *Proceedings EuroSpeech4*, pages 1423–1434, 1998. (cité dans la page 84.)

- [ME05] D. MAKRIS et T. ELLIS : Learning semantic scene models from observing activity in visual surveillance. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 35(3):397–408, 2005. (cité dans la page 16.)
- [MGM07] M. MANCAS, B. GOSSELIN et B. MACQ : Perceptual image representation. *Journal of Image and Video Processing*, 2:3, 2007. (cité dans la page 110.)
- [MH00] R. J. MORRIS et D. C. HOGG : Statistical models of object interaction. *International Journal of Computer Vision*, 37(2): 209—215, 2000. (cité dans la page 95.)
- [MHMS12] I. MANDHOUI, A. HAMID, F. MAUSSANG et B. SOLAIMAN. : Sonar image processing for underwater object detection based on high resolution system. *Signal and Document Processing Workshop (SIDOP)*, 2012. (cité dans la page 37.)
- [MK62] Hu. MING-KUEI : Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions*, 8, 1962. (cité dans la page 98.)
- [NJU10] N.COUDRAY, JL.BUESSLER et JP. URBAN : Robust threshold estimation for images with unimodal histograms. *Journal Pattern Recognition Letters archive, Elsevier Science Inc. New York, NY, USA*, 31(9), 2010. (cités dans les pages 61 et 62.)
- [NOS08] A. NAKIB, H. OULHADJ et P. SIARRY : Non-supervised image segmentation based on multiobjective optimization. *Pattern Recognition Letters*, pages 161–172, 2008. (cité dans la page 63.)
- [OO99] C. ORDONEZ et E. OMIECINSKI : Discovering association rules based on image content. *In Proceedings of the IEEE Advances in Digital Libraries Conference*, Mai 1999. (cité dans la page 22.)
- [OPMFA06] A. OPELT, A. PINZ, M. M. FUSSENEGGER et P. AUER : Generic object recognition with boosting. *IEEE Transactions on PAMI*, 2006. (cité dans la page 17.)
- [Ots79] N. OTSU : A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 26(10):62–66, 1979. (cité dans la page 63.)
- [PAA⁺87] S.M. PIZER, E.P. AMBURN, J.D. AUSTIN, R. CROMARTIE, A. GESELOWITZ, T. GREER, B. ter HAAR ROMENY, J.B. ZIMMERMAN et K. ZUIDERVELD : Adaptive histogram equalization and its variations. *Surround design. NASA Technical Memorandum Computer vision, graphics, and image processing*, 39(3): 355–368, 1987. (cité dans la page 30.)

- [Pal99] S. PALMER : *Vision Science: Photons to Phenomenology*. MIT Press, Cambridge, MA, 1999. (cité dans la page 22.)
- [Par08] H. M. PARK : *Univariate Analysis and Normality Test Using SAS, Stata, and SPSS*. Thèse de doctorat, University Information Technology Services Center for Statistical and Mathematical Computing , Indiana University, 2008. (cité dans la page 50.)
- [PG01] S.W. PERRY et L. GUAN : Detection of small man made objects in sector scan imagery using neural networks. *OCEANS, MTS IEEE Conference and Exhibition*, 4:2108–2114, 2001. (cité dans la page 93.)
- [PM04] D. PELLEGG et A. MOORE : *Active Learning for Anomaly and Rare-Category Detection*. Proc. 18th Annual Conference on Neural Information Processing Systems, 2004. (cité dans la page 132.)
- [PP00] C. PAPAGEORGIOU et T. POGGIO : A trainable system for object detection. *Intl. J. Computer Vision*, 38(1):15–33, 2000. (cité dans la page 17.)
- [PS91] G. PIATETSKY-SHAPIRO : Discovery, analysis and presentation of strong rules. *Knowledge discovery in databases.*, pages 229–248, 1991. (cité dans la page 20.)
- [Pun81] T. PUN : Entropic thresholding, a new method. *Comput. Graphics Image Process*, pages 210–239, 1981. (cités dans les pages 67 et 68.)
- [Rac11] N. Mohd RACALI : Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors, and anderson-darling test. *Journal of statistical Computation and Simulation*, 3:21–33, 2011. (cité dans la page 48.)
- [RH99] Y. RUI et T. S. HUANG : Image retrieval: Current techniques, promising, directions and open issues. *Visual Communication and Image Representation*, 10(4):893–908, 1999. (cité dans la page 21.)
- [R.J62] R.JACQUET : *Contribution aux études de plages de confiance d'une droite de Henry*. Thèse de doctorat, Faculté des Sciences de l'Université de Nancy, 1962. (cité dans la page 50.)
- [RLC99] I.T. RUIZ, D.M. LANE et M.J. CHANTLER : A comparison of inter-frame feature measures for robust object classification in sector scan sonar image sequences. *IEEE Journal of Oceanic Engineering*, 24:458–469, oct 1999. (cité dans la page 15.)

- [Ros89] B.H. ROSS : Some psychological results on case-based reasoning. *Case-Based Reasoning Workshop , DARPA, Pensacola Beach. Morgan Kaufmann*, 4:144–147, 1989. (cité dans la page 135.)
- [Ros01] Paul L. ROSIN : Unimodal thresholding. *Pattern Recognition*, 34(11):2083–2096, 2001. (cité dans la page 63.)
- [SA04] P.K. SAHOO et G. ARORA : Image thresholding using two-dimensional tsallis-havrda-charvt entropy. *Pattern Recognit. Lett*, pages 1149–1161, 2004. (cités dans les pages 67 et 68.)
- [SA06] P.K. SAHOO et G. ARORA : Reality check for data mining. *Pattern Recognit. Lett*, pages 520–528, 2006. (cité dans la page 68.)
- [Sch97] B. SCHIELE : *Object Recognition Using Multidimensional Receptive Field Histograms*. Thèse de doctorat, I.N.P. de Grenoble, 1997. (cité dans la page 110.)
- [SCH⁺11] Z. SONG, Q. CHEN, Z. HUANG, Y. HUA et S. YAN : Contextualizing object detection and classification. *In CVPR*, 2011. (cité dans la page 17.)
- [SCZ05] A. SOTO, A. CANSADO et F. ZAVALA : Detection of rare objects in massive astronomical datasets using innovative knowledge discovery technology. *Astronomical Data Analysis Software and Systems XIV ASP Conference Series*, 347:68–69, 2005. (cités dans les pages 16 et 93.)
- [SG91] P. SMYTH et R. M. GOODMAN : Rule induction using information theory. *Knowledge discovery in databases*, pages 159–176, 1991. (cité dans la page 20.)
- [Sim96] E. SIMOUDIS : Reality check for data mining. *IEEE Expert : Intelligent Systems and Their Applications*, 11(5):26–33, 1996. (cités dans les pages 19 et 20.)
- [SRGF01] C. SACCHI, C. REGAZZONI, G. GERA et G. FORESTI : A neural network-based image processing system for detection of vandal acts in unmanned railway environments. *International Conference on Image Analysis and Processing*, pages 529–534, 2001. (cité dans la page 95.)
- [SS04] M. SEZGIN et B. SANKUR : Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 13(1):146–165, 2004. (cité dans la page 59.)
- [SSWC88] P.K. SAHOO, S. SOLTANI, A.K.C. WONG et Y.C. CHEN : A survey of thresholding techniques. *CVGIP*, 1988. (cités dans les pages 61 et 67.)

- [STT11] R. SALAKHUTDINOV, A. TORRALBA et J. TENENBAUM : Learning to share visual appearance for multiclass object detection. *CVPR*, 2011. (cité dans la page 9.)
- [Sun08] Z. SUN : Heavy-tailed rayleigh distribution: A new tool for the modeling of sar amplitude images. *Geoscience and Remote Sensing Symposium, IGARSS*, 2008. (cité dans la page 46.)
- [SWS⁺00] A.W.M. SMEULDERS, M. WORRING, S.SANTINI, A.GUPTA et R. JAIN : Content-based image retrieval at the end of the early years. *IEEE Trans. on Patt. Anal. and Machine Intell*, 22(12): 1349–1380, 2000. (cité dans la page 22.)
- [TC03] J. THURESSON et S. CARLSSON : Finding object categories in cluttered images using minimal shape prototypes. In *Image Analysis, 13th Scandinavian Conference, SCIA*, pages 1122–1129, Halmstad, Sweden, June/July 2003. (cité dans la page 17.)
- [TFM99] O. TSUJII, MT. FREEDMAN et SK. MUN : Classification of microcalcifications in digital mammograms using trendoriented radial basis function neural network. *Pattern Recognition*, 32(5): 891–903, 1999. (cité dans la page 126.)
- [TG80] A. TREISMAN et G. GELADE : A feature-integration theory of attention. *Cognitive Psychology*, 12(1):97–136, 1980. (cités dans les pages 16 et 111.)
- [Tom98] B. TOMA : Surveillance des événements rares en santé publique vétérinaire. *Epidémiol. Santé Anim*, 34:1–8, 1998. (cité dans la page 9.)
- [Tsa95] Du-Ming TSAI : A fast thresholding selection procedure for multimodal and unimodal histograms. *Pattern Recognition Letters*, pages 653–666, 1995. (cité dans la page 63.)
- [V.J98] V.JANOO : Quantification of shape, angularity, and surface texture of base course materials. *Special Report 98-1, US Army Corps of Engineers, Cold Regions Research & Engineering Laboratory*, 4:483–495, 1998. (cité dans la page 100.)
- [VP88] H. VOORHEES et T. POGGIO : *Computing Texture Boundaries from Images*, volume 333. Nature, 1988. (cité dans la page 66.)
- [WBLL11] X. WANG, X. BAI, W. LIU et L. J. LATECKI : Feature context for image classification and object detection. In *CVPR*, 2011. (cité dans la page 17.)
- [WIR⁺02] D. WALTHER, L. ITTI, M. RIESENHUBER, T. POGGIO et C. KOCH : Attentional selection for object recognition – a gentle way. *Lecture Notes in Computer Science*, 2525(1):472–479, 2002. (cité dans la page 16.)

- [WKB97] K. WOODS, W.P. KEGELMEYER et K. BOWYER. : Combination of multiple classifiers using local accuracy estimates. *IEEE Trans. On Pattern Analysis and Machine Intelligence*, 19:405–410, 1997. (cité dans la page 106.)
- [WNR74] J.S. WESZKA, R.N. NAGEL et A. ROSENFELD : A thershold selection technique. *IEEE Trans, Comput C-23*, 26(10):1322–1326, 1974. (cités dans les pages 62 et 67.)
- [XG08] T. XIANG et S. GONG : Video behaviour profiling for anomaly detection. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30:893–908, 2008. (cité dans la page 9.)
- [YjZ12] J. YANG et S. j. ZHU : Narrowing semantic gap in content-based image retrieval. In *In Computer Distributed Control and Intelligent Environmental Monitoring (CDCIEM), 2012 International Conference on. IEEE*, page 433–438, 2012. (cité dans la page 23.)
- [YLH06] Sung-Nien YUA, Kuan-Yuei LIB et Yu-Kun HUANG : Detection of microcalcifications in digital mammograms using wavelet filter and markov random field model. *Computerized Medical Imaging and Graphics*, 30(3):163—173, 2006. (cité dans la page 124.)
- [YQY09] Y.ZHAOHUI, S. QUN et C. YINGYING : Automatic recognition of man-made objects in sar images using support vector machines. *Urban Remote Sensing Event*, 1:1–5, 2009. (cité dans la page 94.)
- [YZW07] Jun YANG, Peng ZHANG et Runsheng WANG : Extracting man-made region(s) based on attention driven level-set evolution. *Image and Graphics, ICIG 2007. Fourth International Conference*, pages 465 – 470, Aug 2007. (cité dans la page 16.)
- [ZDGPM06] D. ZHANG, S. Bengio D. GATICA-PEREZ et I. MCCOWAN. : Modeling individual and group actions in meetings with layered hmms. *Multimedia, IEEE Transactions on*, 8(3):509–520, June, 2006. (cité dans la page 95.)
- [Zip49] George Kingsley ZIPF : *Human behavior and the principle of "Least Effort"*. Addison-Wesley, New York, 1949. (cité dans la page 16.)
- [ZSV04] H. ZHONG, J. SHI et M. VISONTAI : Detecting unusual activity in video. In *CVPR*, 2004. (cités dans les pages 16 et 95.)

Résumé

La détection des objets rares joue un rôle important dans différentes disciplines. Dans la littérature, le terme « objet rare » ou « événement rare » est différemment apprécié en fonction des événements rencontrés, de l'état initial, de l'intention de l'utilisateur et du domaine d'application. Les recherches s'intéressant au développement des algorithmes permettant la détection générale des objets rares, et pouvant être partagés par différents domaines d'applications, sont extrêmement limitées.

Cette thèse propose une nouvelle approche sémantique pour la détection automatique des objets rares dans une image naturelle. Contrairement aux travaux s'intéressant à une particularité définie d'un objet rare, l'approche proposée permet de différencier deux catégories principales d'objets : « objet marquant » et « objet rare ». Nous désignons par le terme « objet rare » tout objet peu fréquent qui s'écarte significativement de la majorité des objets fréquemment rencontrés dans l'image. Les objets marquants sont aussi des objets d'une fréquence faible. Cependant, ces objets ne nécessitent pas autant d'intérêt que les objets rares. L'approche de détection proposée est réalisée en deux étapes décisives. Dans une première étape, nous développons une nouvelle approche de segmentation basée sur une mesure de la quantité d'information permettant de localiser les objets d'intérêt dans l'image. Dans l'étape suivante, nous développons une méthode sémantique de fouille des données fondée sur un raisonnement hypothétique. Nous visons à exploiter l'information en continu dans ces données et d'en extraire une sémantique fiable pour la caractérisation commune d'objets rares. La détection finale de l'objet rare est basée sur les méthodes d'apprentissage et la classification non supervisée. Un système de détection de la saillance visuelle est utilisé pour décider de la différenciation entre l'objet marquant et l'objet rare.

Dans ce travail, nous avons défini une nouvelle approche de pré-traitement des images et un système de raisonnement à base de cas pour améliorer les performances du travail réalisé. L'approche que nous avons proposée ne nécessite aucune connaissance préalable sur la nature des objets ni une intervention extérieure. Les résultats d'évaluation de notre approche sur des images réelles et synthétisées ont montré l'efficacité du modèle proposé.

Mots-clés : Objet rare, Détection générale, Fossé sémantique, Segmentation automatique, Raisonnement hypothétique, Méthodes d'apprentissage, Saillance visuelle, Prétraitements, Raisonnement à base de cas

Abstract

The detection of rare objects plays an important role in different disciplines. In literature, the term «rare item» or «rare event» is differently appreciated depending overall on the events encountered, the initial state, user intention and the working environment. Searches interested to the development of rare object general detection algorithms, shared by different fields of application, are extremely limited.

This thesis proposes a new semantic approach for automatic detection of rare objects in a natural image. Contrary to the work concerned with a feature set of a rare item, the proposed approach can differentiate two main categories of objects «aberrant object» and «rare object». By rare object, we mean extremely different objects from usual components of a given image whose characteristics make them highly valuable. A rare object is for us an unusual event with a low probability of occurrence. Aberrant objects are also objects of a lower frequency. However, these objects do not require much interest as the rare items. The proposed detection approach is performed in two critical steps. In the first step, we developed a new segmentation approach based on a qualitative measure of the amount of information to locate objects of interest in the image. In the next step, we developed a semantic data mining method based on a hypothetical reasoning. We aim to exploit continuously the information in these data and to extract reliable common semantics to characterize rare items. The final detection of the rare objects is based on learning methods and unsupervised classification. A saliency detection approach is used to decide the differentiation between the rare and the aberrant object.

In this work, a new approach to pre-process image and a case-based reasoning system are used to improve the performance of the process. Our approach does not require any prior knowledge about the nature of objects nor external intervention. The process is tested on the special case of real and synthesized images. Results of evaluation show the efficiency of the proposed method.

Keywords : Rare object, Detection, Semantic gap, Automatic segmentation, Hypothetical reasoning, Learning methods, Saliency detection, Pre-processing, Case based reasoning