



Traitement et classification parcimonieuse des images radar pour l'aide à la reconnaissance de cibles

Ayoub Karine

► To cite this version:

Ayoub Karine. Traitement et classification parcimonieuse des images radar pour l'aide à la reconnaissance de cibles. Intelligence artificielle [cs.AI]. Université de Bretagne Loire; ENSTA Bretagne - Brest, 2018. Français. NNT: . tel-02096884v1

HAL Id: tel-02096884

<https://theses.hal.science/tel-02096884v1>

Submitted on 11 Apr 2019 (v1), last revised 1 Apr 2020 (v2)

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.

THESE DE DOCTORAT EN COTUTELLE PREPAREE A

L'ECOLE NATIONALE SUPERIEURE
DE TECHNIQUES AVANCEES BRETAGNE
COMUE UNIVERSITE BRETAGNE LOIRE
ECOLE DOCTORALE N° 601
*Mathématiques et Sciences et Technologies
de l'Information et de la Communication*

ET L'UNIVERSITE MOHAMMED V DE RABAT
LABORATOIRE DE RECHERCHE EN INFORMATIQUE ET
TELECOMMUNICATIONS
Spécialité : Informatique

Par **Ayoub KARINE**

**« Traitement et classification parcimonieuse des images radar pour
l'aide à la reconnaissance de cibles »**

Thèse présentée et soutenue le « 03 Décembre 2018 »
Unité de recherche : Lab-STICC, UMR CNRS 6285

Rapporteurs avant soutenance :

Jean-Paul HATON
Abdellah ADIB

Professeur des Universités, Université de Lorraine, Nancy, France
Professeur des Universités, FST-Université Hassan II de Casablanca, Maroc

Composition du Jury :

Président :

Basel SOLAIMAN,
Examineurs :

Jean-Marc LE CAILLEC,
Salma MOULINE,
Benayad NSIRI,
Hicham LAANAYA,

Professeur, IMT Atlantique, Brest, France

Professeur, IMT Atlantique, Brest, France
Professeur des Universités, FSR-Université Mohammed V de Rabat, Maroc
Professeur des Universités, ESET-Université Mohammed V de Rabat, Maroc
MCF-HDR, FSR-Université Mohammed V de Rabat, Maroc

Directeurs de thèse :

Ali KHENCHAF,
Mohammed EL HASSOUNI,
Co-encadrant :
Abdelmalek TOUMI,

Professeur des Universités, ENSTA Bretagne, Brest, France :
MCF-HDR, FLSH-Université Mohammed V de Rabat, Maroc

Enseignant chercheur, ENSTA Bretagne, Brest, France

*À ma grand-mère bien aimée Lhaja Fatna,
qui m'a toujours soutenu et encouragé
mais malheureusement elle nous a
quittés avant de savourer le fruit
de ses efforts inlassables.*

*Le chagrin de ton départ, chère grand-mère,
a été légèrement atténué après la venue
de ma petite princesse : Hafssa.
Je veillerais à l'éduquer pour
qu'elle soit comme tu étais,
tu resteras toujours notre idole
et notre source de bénédiction.*

*À ma mère, mon père
À my second half : Hajar
À mon cher frère : Anass
À ma belle soeur : Hind
À ma nièce adorable : Rita*



REMERCIEMENTS

Cette thèse de doctorat a été menée dans le cadre d'une thèse en cotutelle pour l'obtention du grade de Docteur de l'Université Mohammed V et de l'Université de Bretagne Occidentale.

Les travaux présentés dans ce mémoire ont été effectués au Laboratoire de Recherche en Informatique et Télécommunications (LRIT) de la Faculté des Sciences de Rabat (FSR)-Université Mohammed V au Maroc sous la direction de M. Mohammed EL HAS-SOUNI et au Laboratoire des Sciences et Techniques de l'Information, de la Communication et de la Connaissance (Lab-STICC), sur le site de l'ENSTA Bretagne, sous la direction de M. Ali KHENCHAF et le co-encadrement de M. Abdelmalek TOUMI.

En premier lieu, je tiens à remercier mon directeur de thèse M. Mohammed EL HAS-SOUNI, Professeur Habilité à la faculté des lettres et sciences humaines de Rabat avec qui j'ai travaillé depuis mon stage de Master. Dans une ambiance toujours décontractée mais néanmoins studieuse, il a bien guidé mes premiers pas dans le monde de la Recherche. Et je réitère mes remerciement pour sa grande disponibilité, son aide précieuse, ainsi que pour ses efforts qu'il a prodigués pour l'accomplissement de ce travail de thèse.

Mes sincères remerciements vont également à mon directeur de thèse en France M. Ali KHENCHAF, Professeur des Universités à l'ENSTA Bretagne, de m'avoir accueilli au sein de son équipe REMS et de m'avoir consacré tout ce temps et toute cette énergie malgré son agenda très chargé. J'ai ainsi largement pu profiter de ses conseils toujours pertinents ainsi que de sa rigueur scientifique. J'espère avoir été digne de la confiance qu'il m'a accordée et que ce travail est finalement à la hauteur de ses espérances. Quoi qu'il en soit, j'ai énormément appris à ses côtés et je suis très honoré de l'avoir eu comme directeur de thèse.

Je suis également reconnaissant à mon co-encadrant M. Abdelmalek TOUMI, Enseignant Chercheur à l'ENSTA Bretagne, pour l'encadrement de mes travaux de recherche. Ses conseils, sa disponibilité, les nombreuses discussions et échanges ont grandement contribué à la réussite de cette thèse. Je le remercie aussi d'avoir accepté d'examiner mon travail et de participer en tant qu'examinateur dans le jury final.

Je tiens à remercier M. Basel SOULAIMAN, Professeur à l'IMT Atlantique, d'avoir accepté de présider le jury de ma thèse.

Mers remerciements vont également à M. Abdellah ADIB, Professeur d'Enseignement Supérieur à la faculté des sciences et techniques de Mohammedia, d'avoir accepté de rapporter ce mémoire de thèse.

Je tiens aussi à remercier M. Jean-Paul HATON, Professeur des Universités à l'Université de Lorraine, d'avoir accepté de juger la qualité de mon travail en tant que rapporteur.

Je voudrais également remercier M. Jean-Marc LE CAILLEC -Professeur à l'IMT Atlanique-, Mme. Salma MOULINE -Professeur d'Enseignement Supérieur à la faculté des sciences de Rabat-, M. Benayad NSIRI -Professeur d'Enseignement Supérieur à l'école normale supérieure de l'enseignement technique de Rabat- et M. Hicham LAANAYA - Professeur Habilité Supérieure à la faculté des sciences de Rabat- qui m'ont fait l'honneur d'examiner cette thèse.

J'aurai bien aimé avoir le Feu M. ABOUTAJDINE comme membre de mon jury de thèse, mais malheureusement le destin veut qu'il ne soit plus. Il était parmi les premiers sponsors de cette thèse en cotutelle qui est un résultat direct des collaborations scientifiques tissées par ce grand Monsieur partout dans le monde. Vous nous manquez et sachez bien que nous vous aimions grand Chef!

Je remercie mes amis qui m'ont apporté leur soutien et leurs encouragements tout au long de cette aventure. Dans le désordre, Famille Tarfaoui, Ilyass, Mohcine, Zakariya, Fayçal, Nidal, Haitam, Mehdi, Mounir(s), Hassan, Hamza, Ahmed, Youssef, Mourad(s), Tran Vu, Youness, Jamal, Youssef, Fouad, Yassine, Abderached, Abdelhamid, Abderahmane, Embarek(s), Jihad, Nawal, Othmane, Khalid, Mohammed, Sébastien, Malik, Anass(s), Ali, Rochdi. Je voudrai également remercier tous mes collègues de travail à l'Université de Haute Alsace et particulièrement le corps professoral et le secrétariat du département MMI de l'IUT de Mulhouse.

Je garde le meilleur pour la fin, ma famille qui a supporté toutes les difficultés morales et matérielles pour me soutenir au terme de mes études. Pardonnez-moi si j'étais loin de vos yeux ces dernières années, j'ai une certitude que j'étais très proche de vos cœurs. J'adresse ma profonde gratitude et mon immense reconnaissance à mes raisons d'être, ma mère et mon père, qui m'ont éduqué et orienté. Merci de m'avoir encouragé et soutenu dans mes choix. Nul mot et nulles expressions refléteront le grand amour et la profonde gratitude que je porte pour vous. On dit que les mots du cœur sont merveilleux, tels étaient les mots de mon unique frère Anass, tu es le grand homme sur lequel nous pouvons compter tous, fier de toi, très reconnaissant de la pertinence de tes conseils, de ton soutien et j'espère que ton petit frère a pu rayonner comme tu l'as toujours espéré. À toute la famille et particulièrement mes deux cousins Houssam et Pr. Aziz ABOULMOUHJIR. À mes beaux parents qui m'ont offert la femme de mes rêves qui partage et qui partagera ma vie, Hajar qui, en plus de soutenir un mari a su supporter un thésard. Sans son soutien quotidien, je n'aurais pu relever ces challenges. Dans les derniers mois de ma thèse, un nouveau sourire a pu mettre sa place et s'imposer dans ma vie. Telle fille telle mère. Je vous aime Hajoura et Hafoussa !



TABLE DES MATIÈRES

Liste des abréviations	xi
Liste des figures	xvi
Liste des tableaux	xix
Liste des algorithmes	xix
Résumé	xxi
Abstract	xxiii
1 Introduction générale	1
1.1 Contexte et problématique	1
1.2 Contributions et organisation de la thèse	3
2 Processus d'aide à la reconnaissance de cibles radar	5
2.1 Introduction	6
2.2 Processus général d'aide à la reconnaissance de cibles	6
2.3 Acquisition de données	6
2.3.1 Notions sur les systèmes radars	7
2.3.2 Principe de l'imagerie radar	10
2.3.3 Description des bases de données d'images utilisées	13
2.4 Traitement des images radar (SAR et ISAR)	21
2.4.1 Principe	21
2.4.2 Traitement des images ISAR	21
2.4.3 Traitement des images SAR	22
2.4.4 Synthèse	23
2.5 Extraction de caractéristiques	24
2.5.1 Principe	24
2.5.2 Caractérisation des images ISAR	24
2.5.3 Caractérisation des images SAR	25
2.5.4 Synthèse	26

2.6	Classification et reconnaissance de cibles	26
2.6.1	Principe	26
2.6.2	Classification des images ISAR	27
2.6.3	Classification des images SAR	27
2.6.4	Synthèse	29
2.7	Évaluation des performances du processus d'aide à la reconnaissance de cibles	29
2.8	Conclusion	30
3	Exploitation de la représentation parcimonieuse en vue de la classification des images radar	33
3.1	Introduction	34
3.2	Principe de la parcimonie	34
3.3	Décomposition d'un signal sur un dictionnaire	35
3.3.1	Formulation du problème	35
3.3.2	Méthodes de résolution	36
3.3.3	Types des dictionnaires	38
3.4	Classification basée sur la parcimonie	39
3.5	Conclusion	41
4	Filtrage attentionnel des points caractéristiques SIFT et classification parcimonieuse multitâches	43
4.1	Introduction	44
4.2	Schéma global de l'approche proposée MSKD+MSRC	44
4.3	Traitement et caractérisation des images radar par la méthode MSKD . . .	45
4.3.1	Principe de la saillance visuelle	45
4.3.2	Principe de la méthode SIFT	49
4.3.3	Description de la méthode MSKD	52
4.4	Classification parcimonieuse multitâche	54
4.4.1	Construction du dictionnaire	55
4.4.2	Reconnaissance par une approche parcimonieuse multitâche	55
4.5	Application et résultats	56
4.5.1	Présentation de la démarche d'application et d'évaluation	56
4.5.2	Application aux images ISAR et résultats	57
4.5.3	Application aux images SAR et résultats	60
4.6	Synthèse	63
5	Modélisation statistique et classification parcimonieuse pondérée . . .	67
5.1	Introduction	68
5.2	Schéma global de l'approche proposée	68
5.3	Construction du dictionnaire statistique univarié et pondéré	69
5.3.1	Décomposition en ondelettes complexes	70
5.3.2	Modélisation statistique univariée des lois marginales	73

5.3.3	Calcul des poids par mesure de similarité entre les statistiques marginales	77
5.4	Construction du dictionnaire statistique multivarié et pondéré	81
5.4.1	Dépendance entre les coefficients d'ondelettes complexes	82
5.4.2	Modélisation statistique multivariée des lois jointes	83
5.4.3	Calcul des poids par mesure de similarité entre les statistiques jointes	87
5.5	Reconnaissance via la classification parcimonieuse	91
5.6	Application et résultats	91
5.6.1	Présentation de la démarche d'application et d'évaluation	91
5.6.2	Résultats de reconnaissance en considérant les images ISAR	93
5.6.3	Résultats de reconnaissance en considérant les images SAR	95
5.7	Synthèse	99
Conclusion générale et perspectives		101
Annexes		107
A	Estimation des paramètres statistiques	107
A.1	Cas de la modélisation univariée	107
A.1.1	Distribution Gamma	107
A.1.2	Distribution de Weibull	108
A.2	Cas de la modélisation multivariée	110
B	Description des méthodes de classification utilisées lors de l'évaluation de la deuxième méthode WSRC-KLD proposée	113
B.1	Classifieur KPPV	113
B.2	Classifieur SVM	113
B.2.1	Cas linéairement séparable	114
B.2.2	Cas non-linéaire	116
B.2.3	Classification multi-classe	117
C	Production scientifique	119
Bibliographie		121



LISTE DES ABRÉVIATIONS

ACC	<i>Analyse en Composantes Curvilineaires</i>
ACP	<i>Analyse Composantes Principales</i>
AFD	<i>Analyse Factorielle Discriminante</i>
AFRL	<i>Air Force Research Laboratory</i>
ATR	<i>Automatic Target Recognition</i>
BLBP	<i>Block Local Binary Pattern</i>
CNN	<i>Convolutional Neural Network</i>
DARPA	<i>Defense Advanced Research Projects Agency</i>
DoG	<i>Difference of Gaussians</i>
DWT	<i>Discrete Wavelet Transform</i>
EM	<i>Expectation Maximization</i>
ENSTA	<i>Ecole Nationale Supérieure de Techniques Avancées</i>
EOC	<i>Extended Operating Condition</i>
ESPRIT	<i>Estimation of Signal Parameters by Rational Invariance Technique</i>
FIT	<i>Feature Integration Theory</i>
FVG	<i>Flux des Vecteurs de Gradient</i>
GC	<i>Gaussian Copula</i>
HOG	<i>Histogram of Oriented Gradients</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
DT-CWT	<i>Dual-Tree Complex Wavelet Transform</i>
ISAR	<i>Inverse Synthetic Aperture Radar</i>
JSRC	<i>Joint Sparse Representation</i>
KLD	<i>Kullbak-Leibler Divergence</i>
KPPV	<i>K-Plus Proches Voisins</i>
KS	<i>Kolmogorov-Smirnov</i>
LOOCV	<i>Leave-One-Out Cross-Validation</i>
LPE	<i>Ligne de partage d'eaux</i>

MP	<i>Matching Pursuit</i>
ML	<i>Maximum Likelihood</i>
MRF	<i>Markov Random Field</i>
MSKD	<i>Multiple Salient Keypoint Descriptors</i>
MSRC	<i>Multitask Sparse Representation based Classification</i>
MSTAR	<i>Moving and Stationary Target Acquisition and Recognition</i>
MUSIC	<i>MUltiple SIgnal Classification</i>
NP	<i>Non-deterministic Polynomial</i>
OMP	<i>Orthogonal Matching Pursuit</i>
PDF	<i>Probability Density Function</i>
RADAR	<i>RAdio Detection And Ranging</i>
RF	<i>Radio-Fréquence</i>
RN	<i>Réseaux de Neurones</i>
ROI	<i>Region of Interest</i>
SAR	<i>Synthetic Aperture Radar</i>
SIFT	<i>Scale-Invariant Feature Transform</i>
SOC	<i>Standard Operating Condition</i>
SOCP	<i>Second-Order Cone Programs</i>
SRC	<i>Sparse Representation based Classification</i>
SSF	<i>Signal de Saut de Fréquence</i>
SVH	<i>Système Visuel Humain</i>
SVM	<i>Support Vector Machines</i>
TFI	<i>Transformée de Fourier Inverse</i>
UIT	<i>Union Internationale des Télécommunications</i>
WSRC	<i>Weighted Sparse Representation based Classification</i>
ZCA	<i>Zero Component Analysis</i>

LISTE DES FIGURES

1.1	Scénario d'un système d'observation [Toumi et Khenchaf, 2013]	2
2.1	Schéma global d'un processus d'aide à la reconnaissance de cibles radar.	7
2.2	Illustration du mode <i>stripmap</i> .	12
2.3	Illustration du mode <i>spotlight</i> .	13
2.4	Illustration du mode inverse.	13
2.5	Comparaison entre les modes (a) <i>spotlight</i> et (b) inverse.	14
2.6	Schéma descriptif global de la chambre anéchoïque de l'ENSTA Bretagne [Toumi, 2007].	15
2.7	Principe de reconstruction d'une image ISAR à partir d'un signal à saut de fréquence en utilisant la transformée de Fourier[Saidi, 2010].	16
2.8	Exemple des images ISAR acquises dans la chambre anéchoïque de l'ENSTA Bretagne ainsi que leurs maquettes (vérités terrains) correspondantes [Toumi, 2007, Toumi <i>et al.</i> , 2012].	16
2.9	Configuration d'acquisition des images SAR qui ont alimenté la base de données MSTAR. ϕ représente l'angle de dépression, φ est l'angle d'incidence et ψ correspond à l'angle azimut.	17
2.10	Exemples des images SAR de la base de données MSTAR sous les conditions SOC ainsi que leurs vérités terrains correspondantes.	18
2.11	Exemples des images SAR de la base données MSTAR sous les conditions EOC-1. Le numéro de série de la configuration est donné entre parenthèse.	20
2.12	Exemples des images SAR de la base données MSTAR sous les conditions EOC-2 pour différents angles de dépression.	21
2.13	Composantes des images SAR et ISAR considérées dans le cadre du travail réalisé dans ce mémoire.	23
3.1	Exemple d'un signal parcimonieux.	35
3.2	Schéma de décomposition du signal y dans le dictionnaire A via le vecteur parcimonieux x . Les cases en couleurs signifient les coefficients non nuls tandis que celles en blancs représentent les coefficients nuls.	36
3.3	Résultats de classification en utilisant la méthode SRC sur (a) Une image radar de test appartenant à la classe C1. (b) Le vecteur parcimonieux obtenu $\hat{x}$. (c) Les résidus des 12 classes.	42

4.1	Schéma global de la première approche proposée et appliquée : MSKD+MSRC.	45
4.2	Exemples de stimuli utilisés dans des tâches de recherche de cibles [Wolfe <i>et al.</i> , 2010] . (a) La cible a une couleur différente des autres distracteurs (impossible de ne pas la voir). On dit que la recherche est disjonctive et par conséquent le processus est de type <i>bottom-up</i> . (b) La cible partage plusieurs attributs visuels avec les autres distracteurs : elle a la même couleur que les distracteurs rouges ainsi que la même orientation verticale que les distracteurs verts. La recherche dans ce cas est dite conjonctive et le processus est dit <i>top-down</i> .	47
4.3	Exemple de cartes de saillance des images radar. Première colonne à gauche : images ISAR et SAR. Deuxième colonne à droite : leurs cartes de saillance obtenues par la méthode d'Itti.	50
4.4	Exemple de points clés SIFT des images radar. Première colonne à gauche : images ISAR et SAR. Deuxième colonne à droite : leurs points clés SIFT détectés.	53
4.5	Distributions de points clés SIFT. Première colonne à gauche : images ISAR et SAR. Deuxième colonne au milieu : distribution de points clés SIFT sur la totalité des images. Troisième colonne à droite : distribution de points clés SIFT sur la zone d'intérêt (méthode MSKD).	54
4.6	Schéma de décomposition du signal multi-dimensionnel Y dans le dictionnaire A via la matrice parcimonieuse X . Les cases en couleurs signifient les coefficients non nuls tandis que celles en blancs représentent les coefficients nuls.	56
4.7	Variation du taux de reconnaissance en fonction du nombre d'atomes dans le dictionnaire pour le cas des images ISAR.	58
4.8	Matrices de confusion obtenues pour les différentes méthodes appliquées aux images ISAR : (a) MSKD+MSRC ; (b) SIFT+MSRC ; (c) MSKD+matching ; (d) SIFT+matching	59
4.9	Matrices de confusion pour les différentes méthodes sur la base de données MSTAR sous les conditions SOC : (a) MSKD+MSRC ; (b) SIFT+MSRC ; (c) MSKD+matching ; (d) SIFT+matching.	62
5.1	Schéma global de la deuxième approche proposée et appliquée : WSRC-KLD.	69
5.2	Extraction des caractéristiques d'une image radar en utilisant une modélisation univariée dans le domaine des ondelettes complexes.	69
5.3	Principe de la DT-CWT.	70
5.4	Illustration d'une image ISAR (a) avec les amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).	71
5.5	Illustration d'une image SAR (a) avec les amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).	72
5.6	Illustration d'une image ISAR (a) avec les histogrammes des amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).	73
5.7	Illustration d'une image SAR (a) avec les histogrammes des amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).	74

5.8	Représentation de la densité de probabilité de la loi Gamma, (a) Influence du paramètre de forme b sur la densité de probabilité pour $a = 1$, (b) Influence du paramètre d'échelle a sur la densité de probabilité pour $b = 3$.	75
5.9	Représentation de la densité de probabilité de la loi de Weibull, (a) Influence du paramètre de forme τ sur la densité de probabilité pour $\mu = 1$, (b) Influence du paramètre d'échelle μ sur la densité de probabilité pour $\tau = 3$.	76
5.10	Comparaison entre la PDF empirique et la PDF estimée des lois Gamma et Weibull pour l'amplitude des sous-bandes complexes (b) d'une image ISAR (a).	78
5.11	Comparaison entre la PDF empirique et la PDF estimée des lois Gamma et Weibull pour l'amplitude des sous-bandes complexes (b) d'une image SAR (a).	79
5.12	Courbe représentative de la fonction $\exp(-d_{KLD})$.	81
5.13	Extraction des caractéristiques d'une image radar en utilisant une modélisation bivariée dans le domaine des ondelettes complexes.	82
5.14	Test Chi-plots de trois types dépendances pour une image ISAR (a) et une image SAR (b). La première colonne correspond à la dépendance intra-bande. La deuxième colonne montre la dépendance inter-orientation. La dernière colonne illustre la dépendance inter-échelle.	84
5.15	Ajustement de la PDF empirique de la copule Gaussienne (trait en bleu) à la PDF estimée (trait en rouge) des amplitudes des coefficients d'ondelettes inter-orientation d'une image ISAR. La première colonne présente le cas d'une loi marginale de type Gamma (GC-Gam). La deuxième colonne illustre l'utilisation de la distribution Weibull comme loi marginale (GC-Wbl).	88
5.16	Ajustement de la PDF empirique de la copule Gaussienne (trait en bleu) à la PDF estimée (trait en rouge) des amplitudes des coefficients d'ondelettes inter-orientation d'une image SAR. La première colonne présente le cas d'une loi marginale de type Gamma (GC-Gam). La deuxième colonne illustre l'utilisation de la distribution Weibull comme loi marginale (GC-Wbl).	89
5.17	Variation du taux de reconnaissance en fonction du nombre d'atomes statistiques dans le dictionnaire pour le cas des images ISAR. La première et la deuxième ligne correspondent respectivement aux dictionnaires statistiques univarié et multivarié.	93
5.18	Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas des images ISAR	95
5.19	Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas de la version SOC de la base données MSTAR.	97



LISTE DES TABLEAUX

2.1	Les bandes de fréquence des ondes électromagnétiques.	8
2.2	Répartition des images SAR d'apprentissage et de test dans la base de données MSTAR sous les conditions SOC.	19
2.3	Nombre d'images SAR d'apprentissage et de test dans la base de données MSTAR sous les conditions EOC-1. Le numéro de série de la configuration est donné entre parenthèse.	19
2.4	Nombre d'images SAR d'apprentissage et de test dans la base de données MSTAR sous les conditions EOC-2.	20
2.5	Matrice de confusion d'un problème de classification binaire.	30
4.1	Taux de reconnaissance (%) des images ISAR pour différentes méthodes en comparaison avec la méthode proposée (MSKD+MSRC).	58
4.2	Temps d'exécution (s) des images ISAR pour différentes méthodes en comparaison avec la méthode proposée (MSKD+MSRC).	60
4.3	Taux de reconnaissance (%) des images SAR pour différentes méthodes en comparaison avec la méthode proposée (MSKD+MSRC).	61
4.4	Comparaison entre les matrices de confusion (%) obtenue avec la méthode proposée (MSKD+MSRC) et avec les autres méthodes dans le cas de la base de données MSTAR sous les conditions EOC-1 (variation des configurations).	63
4.5	Comparaison entre les matrices de confusion (%) obtenues avec la méthode proposée (MSKD+MSRC) et avec les différentes méthodes en considérant la base de données MSTAR sous les conditions EOC-2 (variation des angles de dépression).	64
4.6	Temps d'exécution (en secondes) de la méthode proposée (MSKD+MSRC) sur les images SAR en comparaison avec les autres méthodes.	65
4.7	Synthèse des résultats obtenus en utilisant la méthode proposée (MSKD+MSRC) dans le cas des images SAR et ISAR.	65
5.1	Coefficients d'asymétrie des images SAR et ISAR.	74
5.2	Pourcentage de rejet de l'hypothèse nulle en utilisant le test de Kolmogorov-Smirnov appliqué sur les amplitudes des coefficients DT-CWT des images radar pour deux modèles statistiques univariés (Weibull et Gamma).	77

5.3	Pourcentage de rejet de l'hypothèse nulle en utilisant le test de Kolmogorov-Smirnov appliqué sur les amplitudes des coefficients DT-CWT des images radar pour deux modèles statistiques multivariés (GC-Wbl et GC-Gam).	87
5.4	Dimensions des descripteurs correspondants aux modélisations univariées ou multivariées pour différentes échelles de décomposition.	92
5.5	Taux de reconnaissance (%) des images ISAR pour différentes méthodes statistiques en comparaison avec la méthode proposée WSRC-KLD.	94
5.6	Taux de reconnaissance (%) des images SAR pour différentes méthodes statistiques en comparaison avec la méthode proposée WSRC-KLD.	96
5.7	Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas de la version EOC-1 de la base données MSTAR.	98
5.8	Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas de la version EOC-2 de la base données MSTAR.	98
5.9	Synthèse des résultats obtenus pour les images SAR et ISAR en utilisant la méthode proposée (GC-Gam+WSRC-KLD) au troisième échelle de décomposition.	99
B.1	Noyaux du SVM.	116



LISTE DES ALGORITHMES

3.1	Algorithme de SRC	41
A.1	Méthode de Newton-Raphson pour l'estimation du paramètre de forme b de la loi Gamma	109
A.2	Méthode de Newton-Raphson pour l'estimation du paramètre de forme τ de la loi de Weibull	110
B.1	Algorithme des k-plus proches voisins	113



RÉSUMÉ

La reconnaissance automatique de cibles est toujours une problématique d'intérêt dans différents domaines d'application (sécurité, surveillance, automobile, environnement, médecine, ...). Dans le cadre du travail réalisé, nous nous sommes intéressés au développement d'une méthodologie dédiée à la reconnaissance de cibles à partir des images radar à synthèse d'ouverture (directe ou inverse). Dans ce contexte, différentes techniques développées dans la littérature souffrent de certaines lacunes selon la nature des données traitées (hétérogènes, multimodales, ...), la précision, la robustesse vis-à-vis du bruit et le temps de calcul. Dans ce travail, l'objectif principal porte sur le développement d'outils pour l'aide à la reconnaissance de cibles à partir des images radar. Ainsi, deux bases de données d'images ont été considérées. D'une part des images ISAR (Inverse Synthetic Aperture Radar), récoltées dans la chambre anéchoïque de l'ENSTA Bretagne. Et d'autre part des images SAR (Synthetic Aperture Radar) de la base de données MSTAR. Pour atteindre l'objectif d'amélioration du processus de reconnaissance étudié et développé, et en dehors des méthodes proposées au niveau du traitement et d'extraction de caractéristiques, nous nous sommes intéressés tout au long de la phase de reconnaissance à l'apport de la classification parcimonieuse des images radar. Dans ce sens, la première contribution porte sur la proposition d'un dictionnaire formé par les descripteurs SIFT (Scale Invariant Feature Transform) filtrés par la méthode de la saillance visuelle. Ensuite, en utilisant ce dictionnaire, une classification parcimonieuse multitâche est appliquée dans la phase de reconnaissance. Quant à la seconde contribution, elle intègre la modélisation statistique des images radar considérées dans le domaine des ondelettes complexe. Les paramètres statistiques résultants (univariés ou multivariés) ont été mis à profit pour construire un dictionnaire statistique. Ce dictionnaire est pondéré par la suite en utilisant une mesure de similarité qui intègre la KLD (Kullbak-Leibler Divergence) entre les paramètres statistiques. Les performances des deux contributions ont été évaluées empiriquement sur les deux bases de données distinctes d'images radar (ISAR et SAR).

Mots clés : images radar (ISAR/SAR), saillance visuelle, SIFT, transformées en ondelettes, modélisation statistique, classification parcimonieuse, reconnaissance automatique de cibles.



ABSTRACT

Automatic target recognition has become a flourishing research topic in remote sensing. This problematic is of paramount importance in several military and civilian applications (security, surveillance, automobile, environment, medicine, ...). In this work, we focus on the development of new methodology dedicated to the target recognition from synthetic aperture radar images (inverse or direct). In this context, the different methods proposed in the literature have several drawbacks according to the type of used data (heterogeneous, multimodal, ...), the accuracy, the robustness to noise and the computation time. In this work, we aim to propose new methods for targets recognition from radar images. Thus, two different databases are considered. On the one hand, we use the ISAR (Inverse Synthetic Aperture Radar) images acquired from the anechoic chamber of ENSTA Bretagne. On the other hand, we exploit the SAR (Synthetic Aperture Radar) images of MSTAR database. To achieve the goal of the amelioration of the recognition process studied and developed, we give a special interest to the SRC (Sparse Representation-based Classification) method to recognize the radar images. This method includes also the processing and feature extraction steps to build the dictionary. In this optic, the first contribution consists on constructing a new dictionary composed by the SIFT (Scale Invariant Feature Transform) descriptors filtered by the saliency attention method. After that, this dictionary is exploited by a multi-task sparse classifier to achieve the recognition step. In the second contribution, we statistically model the radar images in the complex wavelet domain. The resulting statistical parameters (univariate or multivariate) are stacked together to construct the statistical dictionary. Afterwards, this dictionary is weighted by using a similarity measure that includes the KLD (Kullbak-Leibler Divergence) between the statistical parameters. The performances of the two proposed methods have been evaluated empirically on two different databases of radar images (ISAR and SAR).

Keywords : radar images (ISAR/SAR), saliency attention, SIFT, wavelet transform, statistical modeling, sparse classifier, automatic target recognition.

1.1 Contexte et problématique

Dans l'objectif d'affiner l'observation et la caractérisation à distance du globe, le progrès technologique est inédit et incessant dans le domaine de la télédétection (en anglais, *Remote Sensing*). Cette dernière est une discipline qui englobe l'ensemble des techniques permettant d'acquérir des informations sur des scènes ou objets observés à distance. Ce progrès technologique inclut principalement l'apparition et le développement de nouveaux systèmes d'observation et d'acquisition. Parmi eux, on distingue le radar (en anglais, *Radio Detection And Ranging*) qui est un système actif pouvant être utilisé de jour comme de nuit et quelques soient les conditions météorologiques. Ces deux avantages se sont traduits par une expansion des travaux de recherche dotant ce système par des nouvelles fonctionnalités et capacités de plus en plus sophistiquées.

Le radar a été conçu principalement pour détecter et localiser des cibles observées de types terrestres, navales ou aériennes (Cf. Figure 1.1). Dans le cas des cibles terrestres et navales, le radar est souvent embarqué sur des porteurs (aéroportés, satellites, ...). Tandis que dans le cas des cibles aériennes, le radar est souvent situé au sol. Le principe du radar est basé sur la propagation des ondes électromagnétiques émises par l'émetteur, et réfléchies par la cible observée. Les ondes réfléchies et captées par le récepteur sont ensuite analysées. À partir de ces ondes, des traitements sont souvent appliqués pour transformer, représenter et caractériser davantage la cible détectée. Nous pouvons citer l'obtention des profils de distance [Hudson et Psaltis, 1993, Jacobs et O'Sullivan, 2000] et l'imagerie 2D (SAR et ISAR) [Toumi, 2007, El-Darymli, 2015]. Cette dernière reste un choix judicieux de représentation de la cible observée du fait qu'elle fournisse une information visuelle riche de connaissance sur la cible radar observée. À partir de ces images radar, une panoplie de méthodes ont été proposées pour répondre aux exigences attendues dans plusieurs domaines d'application : reconnaissance de cibles coopératives ou non coopératives qui constitue l'une des problématiques principales traitées dans le présent travail. Cette problématique est d'intérêt dans différents domaines : surveillance, contrôle, identification, L'objectif dans le développement d'un outil d'aide à la reconnaissance de cibles serait de contribuer à la mise en œuvre de fonctions automatisées dans le processus de reconnaissance (du type ATR : Automatic Target Recognition) en associant une

identité (étiquette ou *label* en anglais) à chaque cible détectée. Dans le cadre du travail réalisé et présenté dans ce mémoire, l'un des objectifs visés est le développement de méthodes de traitement innovantes et robustes permettant l'amélioration du processus de reconnaissance de cibles radar à partir des images radar (ISAR : Inverse Synthetic Aperture Radar et SAR : Synthetic Aperture Radar). Dans la littérature ouverte, on distingue différents travaux qui ont pour objet différents développements sur cette problématique. On peut indiquer notamment les travaux de [El-Darymli *et al.*, 2016] qui ont porté sur la reconnaissance à partir des images SAR.

Cependant, il n'existe pas de travaux menés pour traiter conjointement les images ISAR et SAR. En effet, l'exploitation conjointe des images SAR et ISAR reste un défi majeur vu la différence de leurs modes d'acquisition et par conséquent de leurs contenus visuels. Ainsi, notre travail vise l'étude et l'analyse des méthodes et algorithmes récents exploitant la parcimonie des signaux et des images, avec une application aux images ISAR et SAR.




FIGURE 1.1 – Scénario d'un système d'observation [Toumi et Khenchaf, 2013]

D'une manière générale, les systèmes de reconnaissance automatique de cibles (les ATR) ont tiré beaucoup profit des progrès technologiques non seulement en traitement du signal et des images, mais aussi en s'appuyant sur des techniques en apprentissage automatique. Cette famille de techniques d'apprentissage automatique vise à reconnaître des nouvelles données qui se présentent à l'entrée d'un système en s'appuyant sur les connaissances *a priori* et apprises. Cela permet finalement de munir les systèmes classiques d'une intelligence proche et comparable à celle de l'être humain, introduisant le principe de l'intelligence artificielle (en anglais, *artificial intelligence*). Parmi les techniques dédiées à l'apprentissage automatique, on distingue celles dites de l'apprentissage (ou classification) supervisé et les techniques de l'apprentissage non supervisé. En s'inspirant du fonctionnement du cerveau humain, l'apprentissage supervisé permet de prédire la classe d'un individu en se basant sur des modèles appris sur des individus annotés. Dans ce contexte, la classification parcimonieuse a suscité un intérêt croissant au sein de la

communauté de la télédétection. Cette méthode de classification est inspirée du principe de la parcimonie qui est une discipline qui trouve ses origines en traitement du signal. Le nombre des publications citant le terme parcimonie est en croissance exponentielle. Des sessions spéciales traitant les problématiques liées à la parcimonie ont vu le jour dans les revues et les conférences les plus prestigieuses. La représentation par parcimonie considère qu'un signal ou une image peut être représenté par une combinaison linéaire d'un petit nombre d'atomes (colonnes) choisis dans une structure matricielle appelée dictionnaire. Ce principe est connu sous le nom de la décomposition parcimonieuse. Dans le contexte de l'apprentissage supervisé (classification supervisée), dans le travail pionnier [Wright *et al.*, 2009a], une nouvelle méthode de classification basée sur la parcimonie (SRC, *Sparse Representation Based Classification*) a été proposée. Quoique envisagée initialement pour la reconnaissance des visages [Wright *et al.*, 2009a], cette méthode a connu différentes améliorations et adaptations pour traiter différentes applications. Ainsi, le travail présenté dans ce mémoire tente d'adapter et d'améliorer cette technique de classification basée sur la parcimonie dans la problématique de reconnaissance de cibles radar. Cette méthodologie développée est ensuite appliquée à deux bases de données d'images radar : une base d'images ISAR issue des mesures réalisées dans la chambre anéchoïque de l'ENSTA Bretagne [Toumi, 2007] et une base d'images SAR (benchmark MSTAR) [Keydel *et al.*, 1996].

1.2 Contributions et organisation de la thèse

Hormis l'introduction générale qui constitue le chapitre 1, la suite de ce mémoire est organisée en quatre chapitres. Le chapitre 2 est consacré à la description des différentes composantes d'un processus d'aide à la reconnaissance de cibles. Nous commençons par une présentation du schéma général d'un processus de reconnaissance tout en mettant l'accent sur ses différentes étapes notamment l'étape de traitement, l'étape d'extraction de caractéristiques et l'étape de classification et reconnaissance. Ensuite, nous présentons les deux principales bases de données utilisées pour l'évaluation de la méthodologie adoptée. La première base est constituée d'images ISAR, quant à la seconde, elle est constituée d'images SAR. Les modes d'acquisition de chacune des deux types d'images (ISAR et SAR) sont ensuite décrits. En dernière section de ce deuxième chapitre, une synthèse contenant un bilan comparatif sur l'état de l'art de chaque étape d'un processus de reconnaissance de cibles est présentée. Ce chapitre se termine par la description des outils quantitatifs permettant l'évaluation des performances d'un outil de reconnaissance de cibles.

Le chapitre 3 est consacré aux aspects théoriques de la classification par parcimonie. Nous commençons par décrire les concepts de base de la parcimonie. Ensuite, nous introduisons la décomposition parcimonieuse qui est définie par la méthode de résolution parcimonieuse ainsi que le choix du dictionnaire. Le lien entre cette décomposition et la classification a été présenté.

Dans le chapitre 4, nous décrivons la première approche proposée. Cette dernière est composée de deux étapes séquentielles. La première étape consiste en le traitement et la caractérisation des images radar en combinant deux méthodes à savoir la méthode SIFT (Scale Invariant Feature Transform) et la méthode de la saillance visuelle. Ainsi, le fondement théorique de ces méthodes est décrit. Ensuite, l'approche proposée pour leur combinaison est discutée. Quant à la deuxième étape, elle consiste en l'application de la classification parcimonieuse multitâche sur les descripteurs résultants de l'étape antérieure. Ceci en considérant chaque descripteur SIFT saillant calculé étant une tâche. Cela a été expliqué en détail dans la section 4.4 de ce chapitre. Avant de conclure avec un bilan sur le travail présenté dans ce chapitre, nous exposons une étude empirique de notre première contribution sur la problématique de reconnaissance de cibles à partir d'images ISAR et SAR.

Dans le chapitre 5, nous nous focalisons sur la création des dictionnaires spécifiques pour réaliser la fonction de classification utilisée pour reconnaître un vecteur d'entrée (vecteur de la base de test). Nous avons opté, dans ce travail, que ces dictionnaires aient un caractère statistique. Pour ce faire, nous transformons dans un premier lieu l'image radar dans le domaine des ondelettes complexes. Après cela, nous modélisons statistiquement les coefficients résultants. Deux types de modélisations ont été utilisés. La première concerne la modélisation univariée pour décrire les statistiques marginales des sous-bandes complexes. Quant au deuxième type qui est la modélisation multivariée, il s'intéresse à l'étude des dépendances entre les coefficients de ces sous-bandes. Ainsi, les paramètres statistiques résultants composeront le descripteur de l'image radar et par conséquent l'atome du dictionnaire. Étant donné un vecteur de test qui est aussi décrit par la même approche statistique, nous calculons sa similarité avec tous les atomes du dictionnaire. Cette information de similarité est considérée comme le poids de l'atome à représenter le vecteur de test. De cela, chaque atome est multiplié par son poids pour avoir à la fin un dictionnaire spécifique et bien adapté avec le vecteur de test. Ces différentes étapes ont été discutées en détail dans la section 5.3 pour le cas de la modélisation univariée et dans la section 5.4 pour le cas de la modélisation multivariée. Pour la phase de reconnaissance, nous avons utilisé la méthode SRC. Les résultats de simulation obtenus en appliquant ce concept proposé sont présentés dans la section 5.6. Dans ce contexte, nous avons effectué différents tests en utilisant les images ISAR et SAR.

Pour clôturer ce mémoire, une conclusion générale présente un bilan sur l'ensemble des travaux réalisés. Ensuite, nous avons dressé quelques perspectives et améliorations qui peuvent être une suite logique des travaux réalisés et présentés dans ce mémoire.

Enfin, les annexes A et B ont servi comme compléments des concepts présentés dans le chapitre 5. Quant à l'annexe C, elle liste la production scientifique résultante de l'ensemble des travaux de thèse réalisés.

PROCESSUS D'AIDE À LA RECONNAISSANCE DE CIBLES RADAR

Sommaire

2.1	Introduction	6
2.2	Processus général d'aide à la reconnaissance de cibles	6
2.3	Acquisition de données	6
2.3.1	Notions sur les systèmes radars	7
2.3.2	Principe de l'imagerie radar	10
2.3.3	Description des bases de données d'images utilisées	13
2.4	Traitement des images radar (SAR et ISAR)	21
2.4.1	Principe	21
2.4.2	Traitement des images ISAR	21
2.4.3	Traitement des images SAR	22
2.4.4	Synthèse	23
2.5	Extraction de caractéristiques	24
2.5.1	Principe	24
2.5.2	Caractérisation des images ISAR	24
2.5.3	Caractérisation des images SAR	25
2.5.4	Synthèse	26
2.6	Classification et reconnaissance de cibles	26
2.6.1	Principe	26
2.6.2	Classification des images ISAR	27
2.6.3	Classification des images SAR	27
2.6.4	Synthèse	29
2.7	Évaluation des performances du processus d'aide à la reconnaissance de cibles	29
2.8	Conclusion	30

2.1 Introduction

Ce chapitre vise à présenter les différentes étapes importantes constituant le processus d'aide à la reconnaissance de cibles radar. Elles sont au nombre de 3 étapes accompagnées d'une phase d'évaluation des performances du processus. La première étape est dédiée à l'acquisition et la collecte de données. Pour ce faire le système radar est privilégié avec l'exploitation des images ISAR et SAR. La deuxième étape porte sur la présentation des différents outils de préparation de données (traitement) et de caractérisation (extraction de caractéristiques) des images ISAR et SAR. Quant à la troisième étape, elle vise la mise en œuvre de différentes méthodes de classification en vue de l'aide à la reconnaissance de cibles à partir des images considérées. Naturellement, ce chapitre s'organise autour de trois étapes du processus d'aide à la reconnaissance. Et il se termine par la présentation de différentes mesures utilisées pour quantifier les performances du processus d'aide à la reconnaissance de cibles.

2.2 Processus général d'aide à la reconnaissance de cibles

Depuis plusieurs années, différents travaux ont été consacrés à la problématique de reconnaissance de cibles radar. En conséquence, différentes méthodologies ont été adoptées soit pour l'exploitation des images ISAR [Toumi, 2007] ou des images SAR [El-Darymli, 2015]. Un des schémas standard de représentation d'un processus d'aide à la reconnaissance de cibles radar est illustré via la Figure 2.1. Il est composé globalement de quatre étapes complémentaires : acquisition de données, traitement et extraction de caractéristiques, classification et interprétation des résultats en vue de l'étape de reconnaissance. Avec une phase dédiée à l'évaluation du processus, les quatre étapes constituent la méthodologie adoptée tout au long du travail réalisé et présenté dans ce mémoire. Les différentes étapes sont ainsi présentées par la suite.

2.3 Acquisition de données

Cette étape est très cruciale dans le processus d'aide à la reconnaissance de cibles. En effet, elle constitue la base de l'ensemble des pré-traitements, traitements, extraction des caractéristiques et la classification des signaux et/ou images considérés. Dans la littérature ouverte, les processus d'aide à la reconnaissance développés exploitent différents types de données radar qui sont collectées dans différentes situations et par conséquent elles ont des caractéristiques différentes (selon le capteur utilisé et le mode d'acquisition adopté) [Toumi, 2007] :

- Mesures réelles acquises sur une zone d'intérêt en utilisant des radars et des cibles réelles,
- Mesures réalisées dans une chambre anéchoïque via des radars réels et des maquettes de cibles à une échelle réduite,




FIGURE 2.1 – Schéma global d'un processus d'aide à la reconnaissance de cibles radar.

- Logiciels qui simulent les échos engendrés par la cible. Parmi ces logiciels, nous citons XPATCH et FEKO.
- Bases de données disponibles

Nous soulignons ici que, dans le cadre du travail réalisé, nous avons eu recours à deux types de données radar. D'une part, nous avons utilisé des images ISAR acquises dans la chambre anéchoïque de l'ENSTA (Ecole Nationale Supérieure de Techniques Avancées) qui ont été exploitées dans le cadre des travaux publiés dans [Toumi, 2007, Toumi *et al.*, 2012]. Et d'autre part, nous avons appliqué la méthodologie adoptée à la base de données MSTAR qui est constituée d'images SAR [Keydel *et al.*, 1996].

D'une manière générale, cette étape d'acquisition de données nécessite la mise en œuvre d'un capteur radar avec la définition de la zone d'intérêt, de différents scénarios et les spécifications des caractéristiques d'un tel capteur. Dans ce sens, l'application privilégiée dans ce travail s'intègre dans le domaine radar. En conséquence, la section suivante fait l'objet de la présentation de différentes notions importantes des systèmes radar nécessaires pour l'acquisition de données.

2.3.1 Notions sur les systèmes radars

2.3.1.1 Définition et historique

Le terme RADAR est l'acronyme de *R*Adio *D*etection *A*nd *R*anging. Comme son nom l'indique, ce dispositif repose sur l'utilisation des ondes électromagnétiques (RAdio) pour détecter (Detection) et localiser (Ranging) la présence de cibles [Lacomme, 2001]. Il trouve initialement ses origines au début du XX^{ème} siècle. En 1904, Christian Hülsmeyer a proposé un brevet qui permet de détecter à distance les objets métalliques distants [Blanchard, 2006]. Cependant, cette découverte était très limitée à cause de sa faible portée qui ne dépassait pas 3 km. Depuis cette invention, plusieurs pays, tels que les

États Unis, la Grande Bretagne, l'Allemagne, la France, l'Italie, la Hollande et le Japon se sont focalisés sur l'amélioration de ce premier système. Ce n'est qu'en 1935, que le radar se fait réellement connaître à travers les travaux de Watson-Watt. Il a pu inventer un radar qui atteint des portées de 60 km. L'application réelle de ce dispositif et la nécessité de son amélioration n'ont vu leur véritable essor qu'au cours de la seconde guerre mondiale. C'est pendant cette guerre que la crédibilité accordée au radar est réellement obtenue. Après guerre, l'évolution du radar ne cesse de croître et devient alors un domaine de recherche très actif [Richards *et al.*, 2010].

Le principe de fonctionnement du radar sera présenté dans la prochaine partie.

2.3.1.2 Principe de fonctionnement

En dehors de son utilisation de base concernant la détection et la localisation d'un objet, l'une des exploitations phares d'un radar est l'extraction à distance des informations sur un objet (fixe ou en mouvement) observé. Pour ce faire, il se base sur le principe de l'émission et la réception des ondes électromagnétiques ou plus exactement sur les ondes Radio-Fréquences (RF). Ces ondes sont émises dans la direction de la zone d'intérêt et se caractérisent par leurs longueurs d'onde (ou leurs fréquences). Les principales bandes de fréquence des radar sont données par le Tableau 2.1. La bande de fréquence radar adoptée doit être conforme avec les standards IEEE (Institute of Electrical and Electronics Engineers). Tandis que la fréquence centrale et la largeur de bande du signal sont soumises aux réglementations de l'UIT (Union Internationale des Télécommunications). Lorsque les ondes électromagnétiques rencontrent un objet distant, elles sont réfléchies en direction du radar. Le signal réfléchi, appelé écho, est généralement porteur d'informations sur l'objet illuminé. Les informations généralement extraites incluent la distance, la vitesse, la position ou autres caractéristiques. Et de plus en plus les systèmes radar d'aujourd'hui sont exploités dans divers secteurs pratiques, incluant le domaine automobile, la reconnaissance de cibles mais aussi des applications en télédétection.

TABLE 2.1 – Les bandes de fréquence des ondes électromagnétiques.

Bandes	Longueur d'ondes (cm)	Fréquences (GHz)
Ka	0.75 à 1.1	26.5 à 40
K	1.1 à 1.67	18 à 26.5
Ku	1.67 à 2.4	12.5 à 18
X	2.4 à 3.75	8 à 12.5
C	3.75 à 7.5	4 à 8
S	7.5 à 15	2 à 4
L	15 à 30	1 à 2
P	30 à 100	0.3 à 1

D'une manière simplifiée, un radar est composé des éléments suivants :

- **Émetteur** : Il génère les impulsions hyperfréquences à la fréquence et la puissance désirées par l'utilisateur. Ces impulsions sont destinées à être diffusées par l'antenne. Le type de l'émetteur peut être par exemple un oscillateur de puissance.
- **Antenne** : C'est la composante la plus visible du radar. Dans l'émission, l'antenne concentre l'énergie émise par le radar dans une direction déterminée. Lors de la réception, l'antenne intercepte l'énergie réfléchi par les objets aux alentours et la transmet au récepteur. Dans le cas d'une configuration monostatique, cette antenne est commune pour l'émission et la réception.
- **Modulateur** : C'est un circuit électronique qui permet d'assurer le stockage de l'énergie pendant les périodes séparant des émissions successives et sa restitution ensuite pendant le temps très bref de l'émission radar.
- **Récepteur** : Il est le cœur de la chaîne du traitement radar vu qu'il fournit les données nécessaires à exploiter pour extraire les informations nécessaires concernant la cible. Son rôle principal est l'amplification du signal. Cela doit être effectué sans déformation du signal initial. C'est pour cela que d'autres tâches sont associées à ce dispositif à l'instar du filtrage. Le récepteur doit veiller à maximiser le rapport signal/bruit du signal réfléchi afin de faciliter son traitement dans la suite de la chaîne.
- **Duplexeur** : Il est utilisé principalement dans la configuration monostatique. Il est le responsable de l'utilisation d'une seule antenne pour l'émission et la réception. Pour ce faire, il transmet le signal d'émission à l'antenne et le signal capté au récepteur.
- **Synchronisateur** : En se basant sur une horloge d'une très grande stabilité, il génère des signaux qui définissent les instants d'émission. Il permet aussi de délivrer des signaux nécessaires à des opérations en temps réel.
- **Traitement et exploitation des signaux** : En traitant le signal brut capté par l'antenne de réception, cette étape vise à fournir des signaux exploitables pour différentes applications (détection, reconnaissance, ...). Dans l'application de reconnaissance visée dans ce travail, et après différents traitements de base, les signaux exploitables sont donnés sous forme d'images radar.

Dans le cadre de l'utilisation et l'exploitation d'un système radar, il est nécessaire de bien préciser la configuration géométrique adoptée, ceci fera l'objet du paragraphe suivant.

2.3.1.3 Types de configuration radar

Nous distinguons principalement trois types de configuration radar : monostatique, bistatique et multistatique [Comblet, 2005]. Comme indiqué précédemment, dans le cas d'une configuration monostatique, l'émetteur et le récepteur sont co-localisés. Autrement dit, ils partagent tous les deux la même antenne. À l'inverse, dans une configuration bistatique, l'émetteur et le récepteur sont spatialement séparés. La configuration multistatique est considérée comme une généralisation du cas bistatique dans laquelle plusieurs radars

placés séparément servent pour la réception. Mathématiquement parlant, la classification de ces configurations repose sur l'angle formé par l'émetteur, la cible et le récepteur. Dans le cas où cet angle est égal à zéro, on dit que la configuration est monostatique [Comblet, 2005].

Chaque configuration a ses propres avantages et inconvénients inhérents. La configuration monostatique reste la plus simple à mettre en œuvre. En plus de ça, il est prouvé que son utilisation par des émetteurs actifs leur donne la possibilité de mieux opérer dans des environnements bruyants. Cependant, dans cette configuration, l'ennemi peut détecter et localiser facilement le radar émetteur. D'un autre côté, les radars bistatiques et multistatiques possèdent une résilience aux fausses mesures, puisque le récepteur est séparé de l'émetteur qui peut être coincé ou endommagé. Contrairement à la configuration monostatique, dans ce cas de figure, la détection et la localisation du radar par l'ennemi deviennent plus compliquées. Cela vient naturellement au détriment de la complexité du système et la nécessité de synchroniser l'ensemble des capteurs [Comblet, 2005]. Généralement, le choix de la configuration dépend de l'application envisagée. Dans le cadre de notre étude, nous utilisons des données radars issues d'une configuration monostatique.

Dans l'objectif de bien cerner la définition et les caractéristiques des images radar, le paragraphe suivant présente différentes notions utiles en imagerie radar.

2.3.2 Principe de l'imagerie radar

Avec l'essor considérable des différents développements en électromagnétisme et en traitement du signal, des images dites radars peuvent se former en se basant sur les ondes reçues par le radar. Les images radar les plus répandues sont les images radar à synthèse d'ouverture inverse (en anglais, ISAR : *Inverse Synthetic Aperture Radar*) et les images radar à synthèse d'ouverture directe (en anglais, SAR : *Synthetic Aperture Radar*). Le point commun entre ces deux modes est l'utilisation de la synthèse d'ouverture du radar pour reconstruire l'image radar. Cette synthèse d'ouverture est obtenue dans le cas du mode ISAR par le mouvement de la cible (le radar dans ce cas est fixe). Tandis qu'elle est réalisée en mode SAR par le mouvement du radar et/ou du porteur (la cible dans ce cas est fixe).

Les images radar obtenues fournissent une représentation en deux dimensions avec différentes résolutions, notamment en distance et en azimuth [Comblet, 2005]. Ces aspects de résolutions qui sont importants au niveau de la qualité des images récoltées sont présentés dans le paragraphe suivant.

2.3.2.1 Résolution en distance

La distance R entre la cible et le radar se calcule à partir de la mesure du temps écoulé entre l'émission et la réception de l'onde (Ω) :

$$R = \frac{\Omega c'}{2} = \delta_d \quad (2.1)$$

Avec c' est la vitesse de la lumière ($3 \times 10^8 \text{ m/s}$). Le facteur $1/2$ tient compte du trajet aller-retour de l'impulsion. Cette distance définit la résolution en distance δ_d . Cette mesure donne aussi une information sur la capacité du radar à distinguer deux objets distants. Si ces deux objets sont séparés par une distance supérieure à δ_d , alors ils seront distingués puisque la superposition entre les impulsions n'est pas présente.

Sachant que l'occupation spectrale du signal dite bande du signal (B) est inversement proportionnelle à sa durée ($\Omega = 1/B$), la résolution en distance peut s'exprimer comme suit :

$$\delta_d = \frac{c'}{2B} \quad (2.2)$$

D'autres types des radars à l'instar de celui à visée latérale et celui à ouverture réelle atteignent leurs résolutions de distance de la même manière. Par conséquent, l'équation (2.2) n'est pas restreinte aux images à synthèse d'ouverture [McCandless et Jackson, 2004].

En considérant un angle d'incidence ($\xi \neq 0$), la résolution en distance peut s'exprimer par :

$$\delta_d = \frac{c'}{2B \sin \xi} \quad (2.3)$$

l'équation (2.3) montre que plus la bande d'émission et l'angle d'incidence seront grandes, meilleure sera la résolution en distance.

2.3.2.2 Résolution en azimuth

Dans le cas de l'imagerie radar classique, l'angle d'ouverture de l'antenne $\delta\theta$ est inversement proportionnel à la dimension de l'antenne L_a [Jakowatz *et al.*, 2012] :

$$\delta\theta = \frac{\rho}{L_a} \quad (2.4)$$

avec ρ représente la longueur d'onde du rayonnement électromagnétique émis par le radar.

La zone éclairée à la distance R du radar aura comme étendue transverse :

$$\begin{aligned} \delta a &= R\delta\theta \\ &= \frac{\rho R}{L_a} \end{aligned} \quad (2.5)$$

Le terme δa définit le pouvoir de résolution en azimuth du radar. Autrement dit, elle présente l'aptitude à séparer deux réflecteurs sur l'axe en azimuth. Plus l'étendue δa sera petite, plus le pouvoir de résolution en azimuth sera d'autant meilleur. L'équation (2.5) montre que δa est inversement proportionnelle à la dimension L_a de l'antenne. Donc, une très bonne résolution en azimuth requiert une très grande dimension (longueur) de l'antenne. Supposons par exemple, une onde de longueur $\rho = 0.04 \text{ m}$ à émettre et une distance de $R = 3000 \text{ m}$ entre l'antenne du radar et la cible. En s'appuyant sur ces paramètres, afin d'obtenir une résolution en azimuth $\delta a = 20 \text{ cm}$, il faut que la dimension

de l'antenne physique soit :

$$\begin{aligned}
 L_a &= \frac{\rho R}{\delta a} \\
 &= \frac{0.04 \times 3000}{0.2} \\
 &= 600 \text{ m}
 \end{aligned} \tag{2.6}$$

Avoir une antenne avec une telle grande dimension n'est pas réalisable en pratique. La configuration de la synthèse d'ouverture en radar permet de combler cette lacune. Ainsi, elle fournit des antennes synthétiques de plus grandes dimensions (en utilisant des antennes réelles de petites dimensions) avec la résolution en azimuth souhaitée. Par conséquent, cela permet d'obtenir des images de meilleures qualités. Cette synthèse d'ouverture peut se réaliser en utilisant différentes modes d'acquisition et dépendent des applications visées [Cumming et Wong, 2005] :

- **Mode *stripmap*** : Tout au long du trajet de vol, l'antenne radar garde la même direction de pointage. Dans ce mode, l'antenne reste orientée perpendiculairement à la direction du déplacement du porteur comme illustré par la Figure 2.2. Cette configuration permet de reconstruire des images SAR.





FIGURE 2.2 – Illustration du mode *stripmap*.

- **Mode *spotlight*** : Durant son trajet de vol, l'antenne radar éclaire la même zone. Ce mode est une amélioration du mode *stripmap* et permet d'obtenir des images de meilleure qualité. Cela est dû à l'ouverture angulaire qui est très importante dans ce cas par rapport au mode *stripmap*, ce qui améliore la résolution en azimuth. Ce mode est utilisé aussi pour produire des image SAR de grande dimension en azimuth. Le principe de ce mode est schématisé par la Figure 2.3.
- **Mode *inverse*** : Contrairement aux modes *stripmap* et *spotlight*, la cible dans ce cas de figure est mobile et le radar est fixe. La cible est généralement placée sur

FIGURE 2.3 – Illustration du mode *spotlight*.

une plaque tournante et effectue un mouvement de rotation par rapport au radar. La Figure 2.4 illustre le mécanisme de ce mode. Cette configuration est équivalente au mode spotlight dans le cas où la cible est fixe et le radar est en mouvement (Cf. Figure 2.5) [Toumi, 2007]. Par conséquent, nous pouvons dire que le mode inverse est un cas particulier du mode *spotlight*. Ce mode permet d'avoir des images ISAR.





FIGURE 2.4 – Illustration du mode inverse.

2.3.3 Description des bases de données d'images utilisées

Tout au long du présent mémoire, les différentes simulations réalisées utiliseront principalement deux bases de données d'images disjointes ISAR et SAR. La présentation des deux bases d'images fait l'objet des paragraphes suivants.

FIGURE 2.5 – Comparaison entre les modes (a) *spotlight* et (b) inverse.

2.3.3.1 Base de données d'images ISAR

Afin de tester la méthodologie adoptée dans le cas de cibles aériennes, nous avons exploité les images ISAR reconstruites à partir des données (signaux) radar acquises dans la chambre anéchoïque de l'ENSTA Bretagne. Cette base d'images a été constituée dans le cadre des travaux de Toumi [Toumi, 2007, Toumi *et al.*, 2012]. La Figure 2.6 illustre les dimensions et les différents constituants de cette chambre. La chambre est équipée de deux antennes radar (une pour l'émission et l'autre pour la réception) et un positionneur sur lequel une maquette peut être placée. Pour diminuer les interférences, ses parois sont revêtues par des matériaux absorbants (cela a été schématisé en triangles noirs dans la Figure 2.6). Un panneau absorbant est également interposé entre les deux antennes pour diminuer leur couplage. Les caractéristiques de la chambre sont paramétrées de l'extérieur en utilisant des équipements spécifiques. Parmi ces équipements, on distingue un ordinateur, un analyseur vectoriel de réseau, un synthétiseur de fréquence et un amplificateur à faible bruit. L'ordinateur permet de paramétrer le radar et de commander le positionneur via le logiciel LabView 7.1. Les paramètres adoptés sont transmis à l'analyseur vectoriel de réseau. Ce dernier commande le synthétiseur de fréquence afin de générer un Signal de Saut de Fréquence (SSF) qui varie entre 2 et 18 GHz. Il est à noter que la méthode de SSF permet d'augmenter la résolution en distance en étalant le spectre de la bande de fréquence. Cette méthode se base sur le découpage fréquentiel du signal à émettre. Plus précisément, le signal est décomposé en une succession de nb impulsions à des fréquences : $t_i = f_0 + i\Delta f$ avec Δf est l'incrément de fréquence. De ce fait, la bande totale B vaut : $B = nb\Delta f$. En réception, le radar reçoit l'écho qui correspond à chaque impulsion émise t_i . Ces échos formeront par la suite le spectre général de la cible. Afin de générer les profils distance représentant la distribution spatiale de la cible, la Transformée de Fourier Inverse (TFI) est appliquée. Cela correspond à l'analyse en distance. Quant à l'analyse en azimut, elle est obtenue en appliquant la Transformée de Fourier Rapide sur les profils distance obtenus. Le schéma global du principe de re-

construction des images ISAR est donné par la Figure 2.7. Notant qu'à partir de ces profils distance, plusieurs images ISAR de la même cible peuvent être reconstruites. Par ailleurs, d'autres techniques dites Haute résolution sont utilisées dans la littérature pour reconstruire les images ISAR à l'instar d'ESPRIT (*Estimation of Signal Parameters by Rational Invariance Technique*) [Radoi, 1999, Krim et Viberg, 1996, Paulraj *et al.*, 1986] et de MUSIC (*MUltiple Signal Classification*) [Radoi, 1999, Kay, 1988]. Le signal généré est ensuite émis par l'antenne de radar en direction de la cible. Le signal réfléchi par la cible et capté par l'antenne de réception est amplifié par l'amplificateur à faible bruit. Il est ensuite transmis à l'analyseur vectoriel de réseau puis à l'ordinateur. Les données récoltées via cette chambre anéchoïque ont été largement utilisées dans plusieurs applications [Radoi, 1999, Comblet, 2005, Toumi, 2007, Saidi, 2010, Rochdi, 2011, Bennani, 2012, Jdey, 2014, Belkhaoui, 2014, Khadra, 2012].




FIGURE 2.6 – Schéma descriptif global de la chambre anéchoïque de l'ENSTA Bretagne [Toumi, 2007].

Les images ISAR utilisées dans le présent travail correspondent à des maquettes de cibles aériennes d'une échelle de $1/48^{\text{ème}}$ (Cf. Figure 2.8) et sont obtenues en mode inverse [Toumi, 2007]. Chaque cible est illuminée par un Signal de Saut de Fréquence (SSF) qui couvre la bande $B = [11.65 \text{ } 18] \text{ GHz}$ avec un saut de fréquence $\Delta f = 50 \text{ MHz}$. Ce qui correspond à 128 points (sauts). Un domaine angulaire global $\Lambda = [-5^\circ \text{ } 95^\circ]$ a été adopté avec un incrément angulaire de $\Delta \nu = 0.5^\circ$. Les mesures ont été réalisées en adoptant une polarisation croisée HV (Horizontal/Vertical) en émission et en réception. Les résolutions en distance et en azimuth valent respectivement 2.4 cm et 2.7 cm. Chaque cible aérienne (classe) est composée de 162 images ISAR de taille 256×256 pixels. Sachant que 12 maquettes (A10, F4, F14, F15, F16, F18, F104, F117, Harrier, Mig29, Rafale et Tornado) de cibles ont été utilisées, la base de données est alimentée par 1944 images ISAR. La Figure 2.8 présente les vérités terrains de chaque maquette ainsi que l'image ISAR correspondante.




FIGURE 2.7 – Principe de reconstruction d'une image ISAR à partir d'un signal à saut de fréquence en utilisant la transformée de Fourier[Saidi, 2010].



FIGURE 2.8 – Exemple des images ISAR acquises dans la chambre anéchoïque de l'ENSTA Bretagne ainsi que leurs maquettes (vérités terrains) correspondantes [Toumi, 2007, Toumi *et al.*, 2012].

2.3.3.2 Base de données des images SAR

Afin d'appliquer la méthodologie développée dans le cadre de la reconnaissance de cibles terrestres, nous avons eu recours à la base de données MSTAR (Moving and Stationary Target Acquisition and Recognition) [Ross *et al.*, 1998] qui est constituée d'images SAR. Cette base de données d'images SAR est le fruit d'un travail collaboratif entre deux organismes : Air Force Research Laboratory (AFRL) et Defense Advanced Research Projects Agency (DARPA). Cette base de données est publique¹ et par conséquent largement utilisée dans la littérature. Les images SAR sont acquises en mode *spotlight* dans la bande X (la fréquence centrale vaut 9.59 GHz) avec une largeur de bande de 0.591 GHz. Les images ont été récoltées en polarisation HH (Horizontale/Horizontale) en émission et en réception. L'angle azimut varie entre 0° et 360°. L'incrément angulaire est égal approximativement à 0.03°. Les résolutions en distance et en azimut valent 0.3047 m [Doo, 2016]. La Figure 2.9 montre le schéma global d'acquisition des images SAR de la base de données MSTAR. Deux versions principales de cette base de données sont disponibles [Keydel *et al.*, 1996] : une version sous les conditions EOC (Extended Operating Condition) et l'autre sous les conditions SOC (Standard Operating Condition). Les deux conditions sont explicitées dans les paragraphes suivants.




FIGURE 2.9 – Configuration d'acquisition des images SAR qui ont alimenté la base de données MSTAR. ϕ représente l'angle de dépression, φ est l'angle d'incidence et ψ correspond à l'angle azimut.

1. La base de données MSTAR peut être téléchargée via le lien suivant : <https://www.sdms.afrl.af.mil/index.php?collection=mstar&page=targets>

2.3.3.3 Images SAR sous les conditions SOC

Dans cette version, les images SAR acquises sous un angle de dépression de 15° sont utilisées pour l'apprentissage et celles récoltées sous un angle de dépression 17° sont exploitées pour le test. La version SOC de MSTAR adopte les mêmes conditions pour les images d'apprentissage et celles de test. Elle contient 10 classes de cibles terrestres : deux tanks (T62 et T72), quatre véhicules de transport de troupes (BRDM2, BMP2, BTR60, BTR70), un tank avec un grand lance-missiles (2S1), un tracteur à chenilles (D7), un camion (ZIL131) et un véhicule d'artillerie sol-air (ZSU234). La Figure 2.10 illustre les images SAR des dix classes de cette base de données. Le nombre et la taille des images d'apprentissage et de test existantes dans chaque classe sont présentés dans le Tableau 2.2.




FIGURE 2.10 – Exemples des images SAR de la base de données MSTAR sous les conditions SOC ainsi que leurs vérités terrains correspondantes.

2.3.3.4 Images SAR sous les conditions EOC

La taille des images SAR sous les conditions EOC est 128×128 pixels. Contrairement à la version de MSTAR sous les conditions SOC, il existe une grande différence entre les images SAR de la base d'apprentissage et celles de la base de test. Ces différences incluent la variation de la configuration (EOC-1) et la variation des angles de dépression (EOC-2) :

- **Variation de configuration (EOC-1)** : la configuration fait référence à l'ajout, la suppression ou le mouvement des composantes de la cible. Comme pour la version SOC, les images SAR d'apprentissage et de test sont acquises respectivement sous les angles de dépression de 17° et 15° . Cette variante de MSTAR comporte trois classes de cibles terrestres : BMP2, BTR70 et T72. Nous présentons dans la Figure 2.11 des exemples des images radar ainsi que les images réelles

TABLE 2.2 – Répartition des images SAR d'apprentissage et de test dans la base de données MSTAR sous les conditions SOC.

Types des cibles (classes)	Nombre d'images d'apprentissage	Nombre d'images de test	Taille des images en pixels
2S1	299	274	158×158
BMP2	233	195	128×128
BRMD2	298	274	128×129
BTR70	233	196	128×128
BTR60	256	195	138×128
D7	299	274	177×178
T62	299	273	172×173
T72	232	196	128×128
ZIL131	299	274	192×193
ZSU234	299	274	158×158
Total	2747	2425	-

des cibles considérées (vérités terrains). Pour chaque classe, nous montrons dans le Tableau 2.3 le nombre des images SAR d'apprentissage et de test.

TABLE 2.3 – Nombre d'images SAR d'apprentissage et de test dans la base de données MSTAR sous les conditions EOC-1. Le numéro de série de la configuration est donné entre parenthèse.

Types des cibles (classes)	Angle de dépression	
	17°(apprentissage)	15°(test)
BMP2	233 (snc21)	196 (snc21) 195 (snc9563) 196 (snc9566)
BTR70	233 (c71)	196 (c71)
T72	233 (snc132)	196 (snc132) 195 (sn812) 191 (sn7)
Total	689	1365

- **Variation des angles de dépression (EOC-2)** : Dans cette configuration, les images SAR acquises dans l'angle de dépression 17° sont utilisées pour l'apprentissage, tandis que celles obtenues sous les angles de dépression 15°, 30° et 45° sont exploitées pour construire la base de test. La Figure 2.12 illustre des exemples des images SAR des trois cibles utilisées dans cette variante pour différents angles de




FIGURE 2.11 – Exemples des images SAR de la base données MSTAR sous les conditions EOC-1. Le numéro de série de la configuration est donné entre parenthèse.

dépressions. Cette variante de MSTAR comporte trois classes de cibles terrestres : 2S1, BRDM2 et 2SU234. Le nombre des images SAR dans chaque classe pour les bases d'apprentissage et de test est donné dans le Tableau 2.4.

TABLE 2.4 – Nombre d'images SAR d'apprentissage et de test dans la base de données MSTAR sous les conditions EOC-2.

Types des cibles (classes)	Angle de dépression			
	Apprentissage	Test		
	17°	15°	30°	45°
2S1	299	274	288	303
BRDM2	298	274	420	423
ZSU234	299	274	406	422
Total	896	822	1114	1148

Dans ce qui suit, nous présentons en revue des méthodes adaptées pour l'aide à la reconnaissance de cibles radar à partir des images radar (ISAR ou SAR). Par conséquent, les termes "images ISAR" et "images SAR" feront référence respectivement à celles de la chambre anéchoïque de l'ENSTA Bretagne et de la base de données MSTAR




FIGURE 2.12 – Exemples des images SAR de la base données MSTAR sous les conditions EOC-2 pour différents angles de dépression.

2.4 Traitement des images radar (SAR et ISAR)

2.4.1 Principe

Avant d'extraire des informations à partir des images radar, des opérations préliminaires sont généralement utilisées. Le but de ces dernières est l'amélioration de la qualité des données et de son contenu informationnel. La phase de traitement vise à préparer les données pour la phase d'extraction de caractéristiques ainsi que la phase de classification. En effet, pour une application de reconnaissance, les images radar traitées sont généralement composées de deux régions : une région dite d'intérêt (*ROI, Region Of Interest*) qui contient la cible observée ainsi qu'une deuxième région comportant l'arrière plan et le reste de l'image.

2.4.2 Traitement des images ISAR

Pour le cas des images ISAR, dans [Kim *et al.*, 2005], les auteurs proposent un algorithme de segmentation composé de deux étapes : la segmentation par seuillage pour regrouper les pixels qui ont les mêmes grandeurs avant d'appliquer une normalisation sur l'image segmentée. Le seuil utilisé dans l'algorithme de seuillage n'est que la moyenne des pixels des images. Quant à la normalisation, les auteurs appliquent une division par la moyenne des valeurs des pixels de l'image. La démarche utilisée a été aussi adoptée par [Yuankui et Yiming, 2007]. Dans le travail de [Wang *et al.*, 2010], une succession de méthodes de la morphologie mathématique sont appliquées sur l'image. Ces opérations mor-

phologiques se basaient principalement sur la fermeture/ouverture morphologique pour réaliser des opérations d'érosion et dilatation. D'autres familles de méthodes se sont focalisées sur l'extraction des contours des images ISAR délimitant la cible sans la prise en compte de l'information de toute la région de la cible. Parmi les premières méthodes apparues pour cette finalité, on cite, l'opérateur laplacien [Ratcliffe, 1997] ou de gradient [Brandwood, 1983], les filtres de Sobel/Roberts [Kanopoulos *et al.*, 1988] ou de Prewitt [Prewitt, 1970] ou de Canny-Deriche [Deriche, 1987]. Les limites de ces méthodes ont été soulevées dans la littérature du fait qu'elles ne fournissent pas des contours fermés [Toumi *et al.*, 2009]. Pourtant ces méthodes classiques constituent la base de la plupart des algorithmes basés contour. Pour détecter le contour, [Toumi *et al.*, 2007] utilisent une segmentation morphologique en appliquant la méthode de ligne de partage d'eaux (en anglais, LPE : *watershed*) sur le gradient de l'image originale. Cela a donné naissance à une sur-segmentation ce qui a amené les mêmes auteurs à adopter une approche hiérarchique. Cette dernière consiste à utiliser les LPE issues d'un niveau donné comme marqueur du niveau suivant [Toumi *et al.*, 2009]. Une hybridation des méthodes de Flux des Vecteurs de Gradient (FVG) et de l'ensemble de niveau (en anglais, *Level Sets*) pour extraire le contour de l'image ISAR a été proposée par [Saidi, 2010]. Dans le travail de [Belkhaoui, 2014], les auteurs extraient le contour de la cible aérienne en utilisant trois différentes techniques : Fisher [Hoover *et al.*, 1996], K-moyenne (en anglais, *K-means*) [Hartigan et Wong, 1979] et le maximum de vraisemblance (en anglais, EM : *Expectation Maximization*) [Moon, 1996].

2.4.3 Traitement des images SAR

Contrairement à l'image ISAR, comme illustrée par la Figure 2.13, la région en dehors de la zone d'intérêt des images SAR est composée à son rôle de deux sous-régions : l'arrière plan et l'ombre. Pour extraire ces deux informations, [Tison *et al.*, 2007] utilisent un traitement pour supprimer le bruit (en anglais, *speckle*) via le filtre de Lee. Par la suite, deux masques sont exploités. Dans le travail de [Power et Wilson, 2000], les auteurs se basent sur la méthode de croissance de région (en anglais, *region growing*) [Chang et Li, 1994] pour segmenter l'image SAR. Dans la méthode proposée par [Dong *et al.*, 2012], les auteurs filtrent l'image SAR par la méthode de Perona et Malik [Perona et Malik, 1990]. Ensuite, une segmentation de l'image filtrée est obtenue en utilisant les champs aléatoires de Markov (*MRF*, *Markov Random Field*) [Zhang *et al.*, 2001]. Les auteurs dans [Chang et You, 2018] proposent plusieurs étapes pour extraire l'ombre. Une segmentation par seuillage est utilisée, suivie d'un filtrage en utilisant la méthode *count* [Gonzalez et Woods, 2012]. Ces traitements sont complétés par deux techniques de la morphologie mathématique qui sont l'ouverture et la fermeture. Dans le travail de [Agrawal *et al.*, 2015], les techniques de l'égalisation de l'histogramme, de filtrage, de seuillage et de dilatation sont appliquées pour séparer la cible de son ombre. Ce même procédé a été adopté par [Bolourchi *et al.*, 2017].

D'autres auteurs considèrent l'ombre et l'arrière plan étant une seule région qui n'est pas utile pour la reconnaissance de la cible. Pour extraire cette région composée de l'ombre et l'arrière plan, la solution la plus triviale est le recadrage (en anglais, *cropping*) qui consiste tout simplement à sélectionner que la zone d'intérêt de l'image (souvent avec une taille réduite de l'image initiale). Cette technique a été adoptée dans plusieurs travaux [Yu *et al.*, 2018, Cho *et al.*, 2017, Li *et al.*, 2017a, Song *et al.*, 2016a]. Les techniques de détection de contour de la cible dans les images SAR de la base de données MSTAR est une approche aussi couramment utilisée dans la littérature. Dans [Sun *et al.*, 2007], les auteurs normalisent dans la première étape de leur algorithme les valeurs des pixels de l'image SAR dans l'intervalle $[0,1]$. Cette normalisation a été effectuée par l'égalisation d'histogramme. Ensuite, un filtrage moyen a été appliquée pour obtenir l'image SAR lissée sur laquelle un seuillage est appliqué pour la segmentation. Sur cette dernière, le filtre de Sobel [Kanopoulos *et al.*, 1988] est utilisé pour détecter le contour de la cible. Pour une étude comparative des méthodes d'extraction de contour à partir des images SAR, le lecteur peut se référer au travail de [Bachofer *et al.*, 2016]. Récemment, les chercheurs donnent une attention particulière à l'application de la saillance visuelle [Itti *et al.*, 1998, Kumar, 2017, Borji et Itti, 2013] sur les image radar [Gao *et al.*, 2017b, Wang *et al.*, 2017, Diao *et al.*, 2016]. Cette méthode consiste à extraire la zone la plus saillante (attirante) dans l'image.




FIGURE 2.13 – Composantes des images SAR et ISAR considérées dans le cadre du travail réalisé dans ce mémoire.

2.4.4 Synthèse

En analysant en revue les méthodes de traitement/préparation des images ISAR et SAR, plusieurs remarques peuvent être notées. Tout d'abord, les filtres classiques ainsi que la morphologie mathématique sont largement utilisés pour les deux types d'images. Ensuite, les images SAR se différencient de celles ISAR (dans les deux bases de données exploitées) par la présence de l'ombre. Cela cause une diversité sur les méthodes appliquées

pour les deux types d'image pour détecter la région d'intérêt. L'ombre dans les images SAR engendre un chevauchement dans la zone de la cible ce qui nécessite un traitement et une adaptation particulière. Dans la première approche proposée dans le cadre de notre travail, nous avons utilisé la méthode de la saillance visuelle comme outil de sélection de la zone délimitant la zone d'intérêt représentée par la région de la cible. Cependant, à notre connaissance, cette méthode n'a jamais été utilisée dans le cas des images radar en présence d'une cible. Cela doit être effectué sous l'hypothèse d'inclusion de l'ombre comme élément de l'arrière plan (région non-cible) de l'image SAR. Après la présentation en revue des méthodes de traitement des images ISAR et SAR, la section suivante a pour objet de présenter des techniques d'extraction des caractéristiques des deux types d'images radar.

2.5 Extraction de caractéristiques

2.5.1 Principe

Cette étape vise à extraire des informations utiles à partir de l'image radar afin de caractériser convenablement son contenu visuel. Généralement, deux familles de méthodes existent dans la littérature. La première famille de méthodes est dite global qui caractérise l'image dans sa globalité. Quant à la deuxième famille, elle s'intéresse à la relation entre les pixels. Elle est appelée description locale. Le grand défi pour les deux familles des méthodes est la production des descripteurs de tailles réduites tout en gardant l'information discriminative de l'image radar.

2.5.2 Caractérisation des images ISAR

Afin d'extraire le vecteur caractéristique de l'image ISAR, sa transformation en domaine polaire [Toumi *et al.*, 2012, Kim *et al.*, 2005] et log-polaire [Toumi et Khenchaf, 2010] a été introduite dans de nombreux travaux. [Toumi et Khenchaf, 2017] ont proposé d'utiliser les pixels de l'image ISAR comme entrée du réseau de neurones profond (en anglais, CNN : *Convolutional Neural Network*) [Krizhevsky *et al.*, 2012, LeCun *et al.*, 2015]. Ce dernier génère un nouveau vecteur caractéristique en se basant sur différents noyaux. Dans le travail de [Wang *et al.*, 2010], les auteurs décomposent au premier lieu l'image ISAR en plusieurs sous-bandes en s'appuyant sur la transformée d'ondelettes. Après cela, la méthode *Block Local Binary Pattern (BLBP)* est appliquée sur chaque sous-bande résultante. Il existe cependant plusieurs recherches qui se sont orientées vers la modélisation des contours pour assurer une invariance aux changements géométriques pour fournir des descripteurs de formes invariants à partir des contours détectés de l'image ISAR. Les auteurs dans [Toumi *et al.*, 2007, Jdey, 2014, Belkhaoui *et al.*, 2013] proposent d'utiliser des descripteurs de Fourier calculés à partir des contours normalisés de l'image ISAR. Dans la méthode proposée par [Belkhaoui *et al.*, 2013], les auteurs fusionnent trois descripteurs de Fourier extraits de trois différentes méthodes de segmentation. Les méthodes de

moments à l'instar de celle de Zernike et Hu sont aussi exploitées dans la littérature [SAIDI *et al.*, 2009] et sont fusionnées avec les descripteurs de Fourier. Notons aussi, que les méthodes d'extraction de caractéristiques produisent des descripteurs d'une grande dimension, alors que des méthodes de réduction d'espace de caractéristiques sont souvent utilisées [Benzécri *et al.*, 1973]. Nous citons la méthode de l'Analyse en Composantes Principales (ACP) [Wold *et al.*, 1987], l'Analyse Factorielle Discriminante (AFD) [Hair *et al.*, 1998] et l'Analyse en Composantes Curvilineaires (ACC) [Demartines et Hérault, 1997].

2.5.3 Caractérisation des images SAR

Pour caractériser l'image SAR de la base MSTAR, plusieurs descripteurs globaux sont proposés dans la littérature. Le vecteur caractéristique proposé dans le travail de [Tison *et al.*, 2007] est composé des informations conjointement extraites de la cible et de son ombre. Parmi ces informations, on trouve les moments de Flusser [Flusser, 2000], les paramètres statistiques des pixels [Tison *et al.*, 2004] et la position relative entre l'ombre et la cible. Dans le travail de [Bolourchi *et al.*, 2017], les moments de Chebyshev [Xiao *et al.*, 2012] sont calculés à partir de trois régions de l'image SAR : l'ombre, la cible et l'image en entier. Par la suite, les moments de Chebyshev sont fusionnés. D'autres méthodes des moments sont aussi utilisées tels que les moments invariants de Hu [Yan *et al.*, 2009] et les moments de Zernike [Amoon et Rezai-Rad, 2013]. Les auteurs dans [Chang et You, 2018] proposent d'extraire les pixels de l'ombre et de la cible séparément. Ces pixels sont fournis ensuite à deux méthodes de classification et leurs scores sont fusionnés. D'autres approches extraient les pixels de l'image SAR et ensuite appliquent des méthodes de réduction de dimension du vecteur caractéristique à l'instar de l'ACP [Mishra et Motaung, 2015, Song *et al.*, 2016a, Li *et al.*, 2017a, Dong et Kuang, 2016b] et le *Zero Component Analysis* (ZCA) [Kang *et al.*, 2017, Chen et Wang, 2014a]. Un sous-échantillonnage en tailles 8×8 et 16×16 pixels a été adopté dans [Dong et Kuang, 2016b]. Les réseaux de neurones profonds qui relient conjointement la phase d'extraction de caractéristiques et de classification sont largement utilisés pour caractériser et classer les images SAR [Housseini *et al.*, 2017, Chen *et al.*, 2016, Chen et Wang, 2014b, Morgan, 2015, Wang *et al.*, 2015, Lin *et al.*, 2017]. Les architectes des réseaux de neurones profonds nécessitent en principe un nombre important des données comme entrées. C'est la raison pour laquelle, les auteurs dans [Ding *et al.*, 2016] utilisent des techniques d'augmentation des données (translation, rotation, ...) pour augmenter l'aspect discriminatif de cette méthode. D'autres techniques multi-résolutions sont aussi utilisées. La transformation de l'image SAR en ondelettes est de plus en plus adoptées aussi. Les auteurs dans [Gomes *et al.*, 2008] appliquent une décomposition de l'image SAR en utilisant la transformée en ondelettes discrète (en anglais, *DWT : Discrete Wavelet Transform*) [Wickerhauser, 1996]. Dans le travail de [Srinivas *et al.*, 2011], les auteurs adoptent la décomposition en ondelettes biorthogonales [Sweldens, 1996]. Les au-

teurs dans [Ruohong et Ruliang, 2008] utilisent les ondelettes de Gabor. Dans les travaux de [Dong *et al.*, 2014b, Dong et Kuang, 2015a, Dong et Kuang, 2015b, Dong *et al.*, 2015, Dong et Kuang, 2015b], les auteurs montrent l'intérêt d'utiliser les ondelettes monogéniques [Felsberg et Sommer, 2001] pour bien caractériser l'image SAR. Les contourlettes [Do et Vetterli, 2005], étant une décomposition en ondelettes géométrique, sont adoptées dans [Yang *et al.*, 2009] pour caractériser l'image SAR. Dans [Song *et al.*, 2016b], les auteurs utilisent la méthode de l'histogramme de gradient orienté (en anglais, *HOG : Histogram of oriented gradients*). Quant à la deuxième famille qui consiste à la description locale de l'image SAR, la méthode SIFT (*Scale-Invariant Feature Transform*) [Lowe, 1999, Lowe, 2004b] est la plus exploitée. Dans [Srinivas *et al.*, 2011], les auteurs fusionnent les descripteurs SIFT avec d'autres descripteurs. Le descripteur proposé par [Knee *et al.*, 2011] est calculé en appliquant la méthode SIFT sur le pyramide spatial de l'image SAR. [Agrawal *et al.*, 2015] extraient les descripteurs SIFT de l'image SAR. Une réduction de la dimension des descripteurs SIFT est adoptée par [Sun *et al.*, 2016]. Cette réduction est obtenue par la pyramide spatiale suivie du *pooling* [Fei-Fei et Perona, 2005].

2.5.4 Synthèse

À l'issue des méthodes généralement utilisées pour caractériser les images ISAR et SAR, nous constatons que le choix de la technique d'extraction du vecteur caractéristique dépend fortement de la méthode utilisée dans la phase de traitement. Par exemple, les descripteurs de formes sont les plus utilisés pour décrire les contours de l'image radar (ISAR et SAR). Parmi ces descripteurs, on cite ceux de Fourier et les méthodes de Moments. La considération de l'ombre est couramment utilisée dans le cas des images SAR de la base de données MSTAR contrairement aux images ISAR. Le descripteur de l'ombre est souvent combiné avec le descripteur de la cible. D'autre part, les approches de la décomposition en ondelettes sont aussi des méthodes communes pour les deux types des images radar. Cependant, elles ont l'inconvénient de la grande dimensionnalité. D'autre part, les descripteurs SIFT sont peu utilisés pour décrire l'information locale des images ISAR et SAR. Cela est à cause des points caractéristiques SIFT qui sont localisés aussi dans l'arrière plan de l'image radar (région non-cible).

Après la présentation de différentes méthodes de caractérisation des images radar, la section suivante passe en revue différentes techniques de classification des images en vue de la phase de reconnaissance de cibles.

2.6 Classification et reconnaissance de cibles

2.6.1 Principe

Le but des étapes antérieures était l'extraction de l'information essentielle et utile caractérisant les images radar. Ces informations sont utilisées par la suite dans la phase de classification et de reconnaissance. Nous distinguons deux types de classification : non-

supervisée (appelée *clustering* en anglais) et supervisée. Pour le cas non-supervisé, on cherche la classe (appelée *cluster* en anglais) de chaque observation sans aucune information sur la nature des classes traitées. Le nombre de classes peut être préalablement connu ou pas. Dans le cas supervisé, on s'appuie sur un ensemble d'individus bien étiqueté dans des classes prédéfinies constituant la dite base d'apprentissage pour définir une fonction de prédiction qui modélise le lien entre chaque individu et sa classe. À partir de cette fonction de prédiction, chaque nouvelle entrée est classifiée. Nous parlons de la base de test pour regrouper toutes les entrées à reconnaître. Dans le présent travail, nous nous focalisons sur la classification supervisée, et par conséquent dans la suite du manuscrit le terme "classification" fait référence à la classification supervisée.

2.6.2 Classification des images ISAR

Dans le cas des images ISAR, plusieurs architectures ont été proposées pour la classification. Dans les travaux de [Toumi, 2007] et de [Kim *et al.*, 2005], une transformation polaire des images ISAR a été proposée. À partir de cette dernière, un vecteur caractéristique a été calculé et une architecture hiérarchique (combinaison hybride et séquentielle) a été proposée en combinant plusieurs classifieurs dont chacun utilise une partie du vecteur des caractéristiques. Cette combinaison hiérarchique (mode série) utilise quatre classifieurs successifs ou chacun corrige les résultats fournis par son prédécesseur. La mise en correspondance (en anglais, *matching*) entre les images ISAR a été proposé par [Yuankui et Yiming, 2007]. Pour ce faire, la distance de Hausdorff a été utilisée. Généralement, les méthodes de classification les plus utilisées sont : Machine à vecteurs de support (en anglais, SVM : *Support Vector Machines*) [Vapnik, 1995], K Plus Proches Voisins (KPPV) [Cover et Hart, 1967] et les réseaux de neurones (RN) [McCulloch et Pitts, 1943]. Il est montré dans plusieurs applications de traitement d'images que la fusion de ces trois méthodes permet d'améliorer les performances de la classification [Laanaya, 2007, Mangai *et al.*, 2010]. Cela a motivé plusieurs auteurs à fusionner les informations fournies par ces méthodes pour la classification des images ISAR. Dans [Jdey *et al.*, 2012b], plusieurs techniques de fusion ont été comparées, à savoir, le vote majoritaire [Penrose, 1946], Bayes [Hartigan, 2012], la théorie de possibilité [Dubois et Prade, 1998] et la théorie des fonctions de croyance [Dubois et Prade, 1988]. Dans ce contexte, l'approche de la fusion floue a été aussi adoptée [Jdey *et al.*, 2012a]. Pour ce faire, deux méthodes sont comparées : Sugeno [Sugeno et Kang, 1988] et Mamdani [Mamdani, 1974]). Récemment, les auteurs dans [Zaied *et al.*, 2018] ont utilisé une architecture de réseau de neurones convolutif.

2.6.3 Classification des images SAR

Afin de classifier les images SAR, plusieurs méthodes de classification sont proposées dans la littérature. Les auteurs dans [Yang *et al.*, 2005] utilisent la méthode KPPV en adoptant un nombre de voisin égal à 3 ($K = 3$). Plusieurs travaux

[Ruohong *et al.*, 2010, Srinivas *et al.*, 2011, Bryant et Garber, 1999, Yan *et al.*, 2009, Anagnostopoulos, 2009, Gao *et al.*, 2017a] privilégient l'application des SVM sur les pixels des images SAR ou sur leurs descripteurs. La méthode Adaboost a été adoptée par [Srinivas *et al.*, 2011, Sun *et al.*, 2005, Wei *et al.*, 2008]. Pour prendre en considération l'imperfection des données radar, plusieurs travaux se sont focalisés sur la fusion des méthodes de classification [Huang et Qiu, 2018, Srinivas *et al.*, 2011, Gao *et al.*, 2017a, Liu et Li, 2013, Yu *et al.*, 2011]. L'apprentissage profond est souvent utilisé conjointement avec la méthode *softmax* [Housseini *et al.*, 2017, Chen *et al.*, 2016, Chen et Wang, 2014a, Morgan, 2015, Wang *et al.*, 2015, Lin *et al.*, 2017, Ding *et al.*, 2016, Du *et al.*, 2016] ou les réseaux de neurones multi-couches [Sun *et al.*, 2013]. Le travail pionnier de [Wright *et al.*, 2009a] présente le principe de l'utilisation de la représentation parcimonieuse des images pour une finalité de classification. Cette méthode est abrégée en SRC (*Sparse Representation-based Classification*). Des traductions française utilisées sont "la classification basée sur la parcimonie" ou "la classification parcimonieuse". Leur contribution avait comme application la reconnaissance de visage. Grâce aux performances remarquables de cette méthode, elle a été adoptée par la communauté de la télédétection pour différentes applications [Li et Du, 2016, Xing *et al.*, 2013, Song *et al.*, 2014, Yu *et al.*, 2018]. À partir d'un dictionnaire composé de pixels ou de descripteurs des données, cette méthode se base sur la résolution d'un problème d'optimisation pour générer les erreurs de reconstruction parcimonieuse appelées résidus. La classe de l'image est celle qui possède le résidu le plus faible. Quant à la reconnaissance des cibles terrestres à partir des images SAR, la méthode SRC ainsi que ses variantes sont largement utilisées. Les auteurs dans [Thiagarajan *et al.*, 2010, Song *et al.*, 2016a, Xing *et al.*, 2014] appliquent le SRC sur les pixels ou sur l'utilisation de l'ACP sur les images SAR. Dans le travail de [Dong *et al.*, 2014b], les auteurs proposent la méthode MSRC (*Sparse Representation of Monogenic Signal*) qui se base sur l'utilisation des ondelettes monogènes comme entrées du SRC. Cela a été améliorée par les mêmes auteurs en intégrant les principes de la fusion de score et de la combinaison des noyaux [Dong et Kuang, 2015a]. L'idée est d'extraire trois composants à partir du signal monogène qui sont : la partie réelle, la partie i-imaginaire et la partie j-imaginaire. Chaque composant est classifiée par la méthode SRC et génère par conséquent un score qui est le résidu. La fusion de ses scores pour les trois composants en utilisant soit la méthode de sommation ou la théorie de Bayes est appliquée pour prédire la classe des images SAR. La fusion des scores de plusieurs SRC reste une solution régulièrement utilisée dans la littérature [Dong et Kuang, 2015b, Dong et Kuang, 2016b, Liu *et al.*, 2014]. D'autres auteurs [Dong *et al.*, 2015, Zhang *et al.*, 2012, Dong *et al.*, 2014a] se focalisent sur l'utilisation de la classification parcimonieuse jointe (en anglais, *JSRC : Joint Sparse Representation*). Ils se basent sur l'intégration jointe de plusieurs informations extraites de l'image SAR dans le même problème d'optimisation. Les différentes variantes de SRC citées ci-dessus se basent sur l'utilisation d'un dictionnaire initial fixe. D'autres travaux adoptent un apprentissage de dictionnaire avant son utilisation dans le problème d'optimisation

[Sun *et al.*, 2016, Dong et Kuang, 2016a, Song *et al.*, 2016b, Yu *et al.*, 2018].

2.6.4 Synthèse

En passant en revue différentes méthodes de classification des images SAR et ISAR, nous pouvons retenir plusieurs points. Les méthodes de classification qui sont communes pour les images SAR et ISAR sont principalement : KNN, SVM, RN et *softmax*. La classification parcimonieuse reste une méthode en plein essor et trouve une place importante dans les processus de reconnaissance de cibles à partir des images SAR. Les variantes de la méthode SRC ne cessent de se développer. Cela est dû à plusieurs facteurs. Tout d'abord, à cause de sa bonne performance dans de nombreuses applications de reconnaissance de forme. Ensuite, plusieurs méthodes sont régulièrement développées pour la construction des nouveaux dictionnaires et pour l'amélioration de la résolution du problème d'optimisation. Nous notons que la parcimonie est une discipline qui trouve son origine dans le traitement du signal. La méthode SRC dépend en premier degré des étapes antérieures du traitement et de l'extraction de caractéristiques. De ce fait, le choix des méthodes pour ces deux étapes doit scrupuleusement être choisi pour un bon fonctionnement du SRC.

2.7 Évaluation des performances du processus d'aide à la reconnaissance de cibles

L'étude des performances et la robustesse d'un processus de reconnaissance de cibles à partir des images ISAR et SAR revient principalement à évaluer la phase de classification. Dans le contexte de la classification supervisée, le partitionnement des données en base d'apprentissage et de test joue un rôle très important. Cela peut se faire en utilisant des méthodes de validation croisée (en anglais, *cross-validation*) [Larson, 1931, Refaeilzadeh *et al.*, 2009]. Parmi ces méthodes on distingue :

- **Hold-Out Validation** : Elle consiste à diviser les données en deux segments (Apprentissage et test) en utilisant des pourcentages.
- **Leave-One-Out Cross-Validation (LOOCV)** : Dans chaque itération, une observation est utilisée pour la phase de test et les autres observations sont utilisées pour la phase d'apprentissage. Le nombre de répétitions de cette opération est égal au nombre global des instances dans la base de données.

Les images de la base de test sont exploitées pour fournir le taux de classification. Cela est établi en comparant les classes réelles (vérités terrains) avec celles prédites par la méthode de classification. Ce taux de classification est extrait généralement à partir de la matrice de confusion. Cette dernière est une matrice carrée de taille égale aux nombres de classes, les lignes représentent les classes réelles et les colonnes correspondent aux classes prédites. La diagonale de la matrice est constituée du taux de classification par classe et tous les éléments situés hors de cette diagonale correspondent aux erreurs de classification. Le Tableau 2.5 représente un exemple d'une matrice de confusion d'un

problème de classification binaire : "+1" (positive) et "-1" (négative). Si le modèle donne une classe positive pour un exemple d'une classe positive, on dit que c'est une classe vraie positive (VP). Si par contre l'exemple appartient à la classe négative on dit que c'est une classe fausse positive (FP). Si le modèle donne une classe négative pour un exemple d'une classe négative, le résultat est une classe vraie négative (VN), si, par contre, la classe de l'exemple est positive, le résultat est qualifié de classe fausse négative (FN). Cette matrice est souvent normalisée afin de faciliter son interprétation (des pourcentages par exemple).

	+1 (Prédite)	-1 (Prédite)
+1 (Réelle)	VP	FN
-1 (Réelle)	FP	VN

TABLE 2.5 – Matrice de confusion d'un problème de classification binaire.

À partir de cette matrice, le taux de classification globale peut se calculer comme suit [Congalton, 1991] :

$$TC = \frac{VP + VN}{VP + FP + FN + VN}. \quad (2.7)$$

Et d'une manière générale, peu importe le nombre des classes, le taux de classification global est obtenu en moyennant les taux de classification situés sur la diagonale :

$$T = \frac{1}{N} \sum_{a=1}^{N_c} M(a, a) \quad (2.8)$$

avec N est le nombre totale des instances, N_c est le nombre de classes et M correspond à la matrice de confusion.

Comme mentionné auparavant, la reconnaissance est un résultat immédiat de la classification. Ainsi, dans la suite de manuscrit nous utiliserons le taux de reconnaissance à la place de taux de classification.

Les processus de reconnaissance de cibles sont aussi évalués en terme de temps d'exécution. Ce dernier est calculé pour chaque étape du processus et ensuite additionné pour avoir le temps d'exécution global. Ce temps est en général divisé sur le nombre total des images afin d'obtenir le temps d'exécution moyen par image. Cependant, il dépend fortement de la station et/ou l'ordinateur utilisé lors des simulations. L'un des objectifs importants dans un processus de reconnaissance de cibles reste de trouver un bon compromis entre le taux de reconnaissance et le temps d'exécution.

2.8 Conclusion

Après avoir effectué une représentation succincte sur les systèmes radar permettant l'acquisition des données exploitées, nous avons décrit les bases de données ISAR et SAR

exploitées pour évaluer la méthodologie adoptée pour l'aide à la reconnaissance de cibles radar. Ensuite, nous avons présenté diverses méthodes utilisées pour la reconnaissance de cibles radar en s'appuyant sur le processus de reconnaissance habituellement utilisé. Plusieurs conclusions peuvent être déduites de cette présentation des différents concepts et méthodes. Tout d'abord, le nombre de méthodes dédiées à la reconnaissance de cibles à partir des images SAR est beaucoup plus importants que celui des méthodes proposées pour la reconnaissance à partir des images ISAR. Cela est dû à la disponibilité au public de la base de données MSTAR constituée des images SAR. Ensuite, à notre connaissance, aucune méthode n'est proposée dans la littérature pour l'aide à la reconnaissance de cibles à partir des deux types d'images ISAR et SAR. Enfin, comme indiqué précédemment, les travaux de recherche qui adoptent le SRC pour reconnaître les cibles terrestres dans les images SAR ne cessent d'accroître. Et plusieurs améliorations de cette méthode ont été proposées dans la littérature, donnant naissance à des taux de reconnaissance remarquables. Néanmoins, à notre connaissance, cette méthode n'est jamais utilisée dans le cadre de la reconnaissance de cibles aériennes à partir des images ISAR.

Nous investiguons tout au long de ce travail de thèse la méthode SRC pour la reconnaissance de cibles radar. Ainsi, le prochain chapitre sera consacré à la description théorique de cette méthode.

**EXPLOITATION DE LA REPRÉSENTATION PARCIMONIEUSE EN VUE DE
LA CLASSIFICATION DES IMAGES RADAR****Sommaire**

3.1	Introduction	34
3.2	Principe de la parcimonie	34
3.3	Décomposition d'un signal sur un dictionnaire	35
3.3.1	Formulation du problème	35
3.3.2	Méthodes de résolution	36
3.3.3	Types des dictionnaires	38
3.4	Classification basée sur la parcimonie	39
3.5	Conclusion	41

3.1 Introduction

Dans la communauté du traitement du signal et des images, la parcimonie est un concept largement étudié ces dernières années. L'idée principale porte sur la représentation de données complexes et de grande taille par peu de paramètres. Elle vise à représenter un signal avec un minimum de coefficients non nuls. Cette orientation permet de résoudre un large panel de problèmes dans différents domaines où l'inversion et l'optimisation sont nécessaires. Par exemples, en compression [Baraniuk *et al.*, 2010], séparation des sources [Bofill et Zibulevsky, 2001], recherche d'images par contenu [Negrel *et al.*, 2014], classification et segmentation des images [Chen *et al.*, 2011]. De ce fait, la manière d'utilisation de la parcimonie varie d'une application à une autre. L'application traitée dans le présent travail porte sur la problématique de reconnaissance de cibles à partir des images radar, par conséquent le signal sera représenté par le vecteur caractéristique de l'image radar à reconnaître. Et par la suite, l'objectif est de trouver sa représentation parcimonieuse dans une structure matricielle appelée dictionnaire. Enfin, l'erreur de la représentation parcimonieuse permet de désigner la classe du vecteur de test (la classe de la cible radar).

Dans ce chapitre, nous commençons par définir les concepts de base de la parcimonie. Ensuite, nous présentons le problème d'approximation parcimonieuse comme un problème d'optimisation. Ce problème va nous amener à décrire brièvement quelques algorithmes permettant de le résoudre. Nous mettons l'accent sur les différents types de dictionnaires utilisés dans la littérature. Enfin, nous nous focalisons sur la description de la classification parcimonieuse.

3.2 Principe de la parcimonie

En traitement du signal, deux types de signaux sont à distinguer : signal continu ou signal discret (dit aussi numérique). Dans le contexte de la problématique abordée dans ce travail, nous nous situons dans le cas de signaux discrets possédant par définition une longueur finie d'échantillons réels. Mathématiquement parlant, nous considérons des vecteurs de $\mathbb{R}^n$ où n est le nombre d'échantillons. Ces signaux sont généralement approximatés par des classes de signaux afin de faciliter leurs manipulations. Parmi ces classes, on distingue les signaux parcimonieux. Par définition, un signal est dit parcimonieux s'il ne contient qu'un nombre réduit de coefficients non-nuls. Un exemple d'un signal parcimonieux est illustré par la Figure 3.1. Un tel signal peut être facilement défini en connaissant les valeurs et les positions des coefficients non-nuls. Ces signaux sont appelés aussi des signaux compressibles. Pour cette raison, l'application la plus spectaculaire de la parcimonie est la compression des signaux et des images en adoptant le principe de l'échantillonnage compressé (en anglais, *compressive sensing*) [Donoho *et al.*, 1998, Baraniuk, 2007].

Afin de quantifier la qualité parcimonieuse d'un signal, on définit ici le support et la norme¹ ℓ_0 d'un vecteur x . Le support, noté supp , est défini comme étant l'ensemble des

1. Ce n'est pas exactement une norme vu qu'elle ne satisfait pas toutes les propriétés d'une norme




FIGURE 3.1 – Exemple d'un signal parcimonieux.

coefficients non-nuls de x . Tandis que la norme ℓ_0 représente le cardinal du support, noté card , qui n'est que le nombre des coefficients non-nuls de x . De ce fait, on a donc :

$$\|x\|_0 = \text{card}(\text{supp}(x)) \quad (3.1)$$

Ainsi, un signal est d'autant plus parcimonieux si sa norme ℓ_0 est faible.

Dans la réalité, peu de signaux ont un caractère parcimonieux. Cependant, on peut trouver une approximation parcimonieuse d'un signal donné.

3.3 Décomposition d'un signal sur un dictionnaire

3.3.1 Formulation du problème

Afin de trouver une approximation parcimonieuse d'un signal y , une technique couramment exploitée est l'utilisation d'un dictionnaire représenté par une matrice. Plus précisément, cette technique consiste à rechercher le vecteur le plus parcimonieux x qui reconstruit approximativement ou exactement le vecteur y par une multiplication linéaire de x avec un dictionnaire A . Ainsi, le problème de la représentation parcimonieuse est formalisé de la façon suivante :

$$P_0 : \quad \underset{x}{\text{argmin}} \|x\|_0 \quad \text{sous la contrainte} \quad y = Ax \quad (3.2)$$

(la propriété d'homogénéité n'est pas vérifiée : pour tout $\kappa \neq 0$, $\|\kappa x\|_0 = \|x\|_0 \neq |\kappa| \|x\|_0$). Cependant, on l'appelle norme par abus de langage, afin de rester cohérent avec la littérature.

Généralement, le dictionnaire $A \in \mathbb{R}^{m \times n}$ est redondant ($m \ll n$). Chaque colonne de ce dictionnaire est appelé atome. Le problème de l'équation (3.2) est schématisé dans la Figure 3.2. Dans cette figure, on remarque que le vecteur x ne possède que quatre éléments non nuls, d'où son caractère parcimonieux. Cela signifie qu'il y a exactement quatre atomes dans le dictionnaire A qui vont contribuer à la représentation parcimonieuse de y . Donc,




FIGURE 3.2 – Schéma de décomposition du signal y dans le dictionnaire A via le vecteur parcimonieux x . Les cases en couleurs signifient les coefficients non nuls tandis que celles en blancs représentent les coefficients nuls.

l'objectif est de trouver la représentation la plus parcimonieuse de x sous une certaine contrainte.

3.3.2 Méthodes de résolution

L'équation (3.2) représente un problème NP (Non-deterministic Polynomial)-difficile du fait que sa résolution exige la considération de toutes les combinaisons possibles d'atomes. Ce qui nécessite un temps exponentiel. Cela n'est pas envisageable dans le cas des dictionnaires possédant un grand nombre d'atomes. Devant cet écueil, plusieurs familles d'algorithmes ont été proposées initialement par la communauté du traitement du signal et des images. Nous décrivons brièvement dans cette sous-section deux familles de méthodes les plus connues. Nous n'entrerons pas ici dans les détails des algorithmes car cela dépasse largement le cadre des travaux réalisés et présentés dans ce mémoire. Néanmoins, différents travaux ont été publiés dans la littérature sur le sujet [Tropp et Wright, 2010].

3.3.2.1 Algorithmes de poursuite

Les algorithmes de poursuite, qui sont aussi appelés algorithmes gloutons (en anglais, *greedy algorithms*), adopte un processus itératif pour résoudre le problème P_0 (Cf. l'équa-

tion 3.2). À chaque itération, l'algorithme ajoute un atome au dictionnaire afin de tendre vers une erreur nulle pour un nombre plus grand d'atomes. L'atome qui minimise le plus l'erreur est maintenu. L'algorithme se poursuit jusqu'à ce qu'un critère d'arrêt soit atteint, ce critère peut être une erreur d'approximation maximale ou un nombre maximal d'itérations.

La méthode de *Matching Pursuit* (MP) [Mallat et Zhang, 1993] est l'algorithme de poursuite de référence. Son principe repose sur la sélection à chaque itération de l'atome le plus corrélé avec le signal d'entrée. Au premier lieu, un résidu initial prend les coefficients du signal d'entrée. Ensuite, pour chaque itération, l'atome qui possède la valeur absolue du produit scalaire le plus grand avec le résidu est sélectionné. Il est à noter que le résidu est renouvelé après chaque itération. Vers la fin, les valeurs des produits scalaires les plus grandes composeront le vecteur parcimonieux. Cet algorithme est caractérisé par sa rapidité vu qu'il se base juste sur des produits scalaires. En contrepartie, il est critiqué par son nombre d'itérations important avant la convergence.

Comme extension de l'algorithme MP, [Pati *et al.*, 1993] proposent l'algorithme *Orthogonal Matching Pursuit* (OMP). Ce dernier adopte le même principe que MP avec une différence dans l'étape de renouvellement des coefficients. En effet, à la place de ne mettre à jour qu'un coefficient par itération, cet algorithme recalcule tous les coefficients en projetant le signal d'entrée sur l'espace engendré par tous les atomes sélectionnés. Cela est réalisé via une orthogonalisation de Gram-Schmidt. De cette manière, l'algorithme OMP converge en un nombre fini d'itérations qui est égale dans le pire des cas à la taille du signal n . Ainsi, il est assuré que le résidu aura une valeur nulle au bout de n itérations.

En s'appuyant sur les bonnes performances des algorithmes MP et OMP, plusieurs variantes se sont succédé. Sans être exhaustif, citons *Stagewise OMP* (StOMP) [Donoho *et al.*, 2012], *Subspace Pursuit* (SP) [Dai et Milenkovic, 2009], *Optimized OMP* (OOMP) [Rebollo-Neira et Lowe, 2002], etc.

3.3.2.2 Algorithmes d'optimisation convexe

Cette famille d'algorithmes se base sur une relaxation du problème P_0 . Il s'agit de remplacer la norme ℓ_0 par la norme ℓ_1 ($\|x\|_1 = \sqrt{\sum_{i=1}^n |x_i|}$) car celle-ci est la plus proche norme convexe [Chen *et al.*, 2001] :

$$P_1 : \quad \underset{x}{\operatorname{argmin}} \|x\|_1 \quad \text{sous la contrainte} \quad y = Ax \quad (3.3)$$

Ce problème est connu dans la littérature sous le nom de *basis pursuit*. En plus, [Donoho et Huo, 2001] ont prouvé que les solutions du problème P_1 (Cf Équation 3.3) sont également solutions du problème P_0 (Cf Équation 3.2). L'avantage de cette relaxation est que le minimum du problème d'optimisation convexe est unique, ce qui présente un avantage par rapport au problème P_0 . En présence des données bruitées, le problème

d'optimisation convexe devient :

$$P_1^\epsilon : \quad \underset{x}{\operatorname{argmin}} \|x\|_1 \quad \text{sous la contrainte} \quad \|y - Ax\|_2 < \epsilon \quad (3.4)$$

avec ϵ est l'erreur d'approximation.

La résolution des problèmes P_1 (Cf. Équation 3.3) ou P_1^ϵ (Cf. Équation 3.4) peut être effectuée en utilisant l'algorithme du point intérieur [Saunders, 2002], les algorithmes basés sur le gradient [Combettes et Wajs, 2005, Wright *et al.*, 2009b], etc.

3.3.2.3 Évaluation de l'algorithme de résolution

Pour évaluer un algorithme de résolution du problème d'optimisation, la qualité de l'approximation parcimonieuse est calculée. Cela est atteint en mesurant la distorsion du signal original y avec le signal approximé $\hat{y}$:

$$\begin{aligned} r &= \|y - \hat{y}\|_2^2 \\ &= \|y - Ax\|_2^2 \end{aligned} \quad (3.5)$$

avec $\|y\|_2 = \sqrt{\sum_{i=1}^n |y_i|^2}$ est la norme ℓ_2 . Cette mesure permet de calculer l'erreur d'approximation parcimonieuse de y par $\hat{y}$. Elle est aussi appelée l'erreur quadratique ou le résidu. Cette mesure augmente lorsque $\hat{y}$ est loin de y et vaut 0 dans le cas où $y = \hat{y}$.

3.3.3 Types des dictionnaires

Le choix du dictionnaire A est très crucial dans les problèmes traitant la parcimonie. Ceci dit, c'est grâce aux atomes contenus dans le dictionnaire que le signal va être traité. Le signal peut être vu comme une phrase et les atomes des mots. Ainsi, on peut construire la phrase en piochant dans le dictionnaire les mots qui vont la composer. Nous rappelons à ce stade que seulement quelques atomes contribuent à estimer le vecteur parcimonieux. Ils sont sélectionnés via le vecteur parcimonieux x . D'une manière générale, on distingue deux types de dictionnaires [Rubinstein *et al.*, 2010] à savoir analytique et celui obtenu par une phase d'apprentissage.

3.3.3.1 Dictionnaire analytique

Il s'agit d'un dictionnaire fixe qui est construit en s'appuyant sur une famille de bases connues à l'instar des ondelettes, curvelets ou contourlettes. Une approche aussi courante dans le cas de signaux 2D (images) est l'adoption des pixels ou les descripteurs des images comme atomes.

Dans ce cas de figure, le choix du dictionnaire doit être obligatoirement en adéquation avec le signal traité. Par exemple, un dictionnaire bien adapté à des images texturées ne donnera pas lieu à une bonne décomposition parcimonieuse pour le cas des images homogènes ou contenant des contours. Le dictionnaire analytique a l'avantage d'être simple d'utilisation et d'être rapide dans l'implémentation.

3.3.3.2 Apprentissage du dictionnaire

Ce type de dictionnaire vise à apprendre le dictionnaire directement à partir des données au lieu d'en utiliser un dictionnaire fixe. L'objectif est de rendre le dictionnaire mieux adapté pour toutes les données d'entrée. Pour cela le problème de minimisation suivant doit être résolu pour chaque signal d'entrée :

$$\underset{x, A}{\operatorname{argmin}} \|x\|_0 \quad \text{sous la contrainte} \quad y = Ax \quad (3.6)$$

Ce problème est similaire à celui de l'équation (3.2), sauf qu'ici on a deux termes à minimiser qui sont x et A . Pour résoudre ce problème, une des solutions consiste à fixer x ou A et ensuite résoudre le problème de minimisation.

Parmi les méthodes d'apprentissage de dictionnaire reportées dans la littérature, on cite les méthodes Bayésiennes [Olshausen et Field, 1997], MOD (Method of optimal Direction) [Engan *et al.*, 1999], K-SVD [Aharon *et al.*, 2006], etc.

3.4 Classification basée sur la parcimonie

L'idée d'intégrer la parcimonie dans les problèmes de classification a été proposée la première fois par [Wright *et al.*, 2009a] pour une application de reconnaissance de visages. Au moment de la rédaction de ce rapport, ce travail a été cité 8298 fois. Cela est dû aux performances impressionnantes obtenues par J. Wright *et al.* dans leur travail pionnier. Cette méthode de classification est connue sous le nom SRC (Sparse Representation-based Classification).

Inspirés par les fondements de la parcimonie, J. Wright *et al.* proposent de présenter l'image de test à classifier comme étant une combinaison linéaire d'un dictionnaire avec un vecteur parcimonieux. Ainsi, pour faire l'analogie avec ce qui a été présenté dans la section 3.3, y représentera le vecteur caractéristique de l'image de test et A le dictionnaire de toutes les images d'apprentissage. Plus précisément, supposant qu'on a nia images d'apprentissage dans la classe $c = \{1, \dots, nc\}$, donc le dictionnaire associé est exprimé comme suit :

$$A_c = [v_{c,1}, v_{c,2}, \dots, v_{c,nia}] \in \mathbb{R}^{m \times nia} \quad (3.7)$$

avec m est le nombre d'éléments d'un atome. Dans le travail de J. Wright *et al.*, la matrice des pixels de chaque image d'apprentissage $I \in \mathbb{R}^{w \times h}$ est transformée en un vecteur $v \in \mathbb{R}^m$, avec $m = wh$. Néanmoins, les valeurs des atomes peuvent être renseignées autrement en utilisant les descripteurs de l'image par exemple. Cela permet une bonne caractérisation des atomes du dictionnaire.

Un vecteur de test $y \in \mathbb{R}^m$ appartenant à la classe c peut être représenté par la multiplication des atomes de la même classe avec un vecteur x_c :

$$\begin{aligned} y &= x_{c,1}v_{c,1} + x_{c,2}v_{c,2} + \dots + x_{c,nia}v_{c,nia} \\ &= A_c x_c \end{aligned} \quad (3.8)$$

Cependant, la classe du vecteur de test y est initialement inconnue, c'est pour cette raison qu'un nouveau dictionnaire est défini. Cette fois-ci, il contient n (tous) échantillons d'apprentissage des nc différentes classes :

$$\begin{aligned} A &= [A_1, A_2, \dots, A_{nc}] \\ &= [v_{1,1}, v_{1,2}, \dots, v_{nc,n_{ia}}] \end{aligned} \quad (3.9)$$

Donc, la représentation linéaire de y en utilisant toutes les échantillons d'apprentissage peut être exprimée comme suit :

$$y = Ax_0 \quad (3.10)$$

avec $x_0 = [0, \dots, 0, x_{c,1}, x_{c,2}, \dots, x_{c,n_{ia}}, 0, \dots, 0]^T$ est un vecteur dont les coefficients sont nuls sauf ceux associés à la classe c . Par conséquent, le vecteur x_0 permet de désigner la classe de y . Ce vecteur doit être le plus parcimonieux possible et il est obtenu en résolvant le système linéaire $y = Ax$ avec une certaine contrainte de minimisation. Cela revient à résoudre le problème présenté dans l'équation (3.2) qui peut être relaxé et transformé au problème de l'équation (3.3). Nous admettons l'hypothèse que les données utilisées dans notre application sont bruitées, de ce fait le problème d'optimisation à résoudre est celui rapporté dans l'équation (3.4). La résolution de ce problème permet de trouver le vecteur parcimonieux $\hat{x}$. Dans le cas idéal, les positions des valeurs non nulles de ce vecteur correspondent à celles des atomes de la même classe dans le dictionnaire (comme le cas du vecteur x_0). Et nous pouvons facilement affecter par la suite le vecteur de test y à cette classe. Cependant, dans la réalité on obtient des valeurs non nulles associées aux positions de différentes classes.

Pour être en adéquation avec la méthode de classification proposée par [Wright *et al.*, 2009a], nous utilisons la méthode *Second-Order Cone Programs* (SOCP)² [Candes et Romberg, 2005] pour résoudre le problème d'optimisation convexe de l'équation (3.4). Cette méthode appartient à la famille des méthodes du point intérieur. Après l'obtention de la solution optimale $\hat{x}$, on calcule pour chaque classe $c \in \{1, \dots, nc\}$, une fonction caractéristique $\delta_c : \mathbb{R}^n \rightarrow \mathbb{R}^n$ qui sélectionne dans $\hat{x}$ juste les coefficients associés à la classe c . En d'autres termes, les valeurs non nulles de $\delta_c(\hat{x}) \in \mathbb{R}^n$ sont les valeurs associées à la classe c dans $\hat{x}$. Par conséquent, la reconstruction de l'image de test y pour la classe c est :

$$\hat{y}_c = A\delta_c(\hat{x}) \quad (3.11)$$

Finalement, la classe de l'image de test y est la classe qui possède la valeur minimale du résidu entre y et $\hat{y}_c$:

$$\begin{aligned} \text{classe}(y) &= \underset{c}{\operatorname{argmin}} r_c(y) \\ &= \underset{c}{\operatorname{argmin}} \|y - \hat{y}_c\|_2 \end{aligned} \quad (3.12)$$

La description générale de la méthode de classification SRC est donnée par l'algorithme 3.1.

2. D'un point de vue applicatif, la librairie *ℓ_1 -magic* a été utilisée

Algorithme 3.1 Algorithme de SRC**ENTRÉES:**

Matrice d'apprentissage $A = [A_1, A_2, \dots, A_{nc}] \in \mathbb{R}^{m \times n}$ pour nc classes

Vecteur de test $y \in \mathbb{R}^m$

Erreur admissible $\epsilon > 0$

Étapes

1 - Normalisation des colonnes de la matrice A

2 - Résolution du problème d'optimisation convexe

$$\underset{x}{\operatorname{argmin}} \|x\|_1 \quad \text{sous la contrainte} \quad y = Ax$$

ou

$$\underset{x}{\operatorname{argmin}} \|x\|_1 \quad \text{sous la contrainte} \quad \|y - Ax\|_2 < \epsilon$$

3 - Calcul des résidus de chaque classe $c \in \{1, \dots, nc\}$

$$r_c(y) = \underset{c}{\operatorname{argmin}} \|y - \hat{y}_c\|_2$$

SORTIES: La classe de y

$$\text{classe}(y) = \underset{c}{\operatorname{argmin}} r_c(y)$$

Nous illustrons dans la Figure 3.3 un exemple de classification d'une image radar de test en utilisant le SRC. Cette image radar appartient à la classe 1 (vérité terrain). Cette classe contient des images d'indices 1 à 97. Dans la Figure 3.3 (b), nous montrons les valeurs des coefficients du vecteur $\hat{x}$ obtenu en résolvant l'équation (3.4). Les coefficients appartenant à la classe 1 sont marqués en rouge. Nous remarquons que ces coefficients sont ceux qui possèdent les plus grandes valeurs. Par conséquent, le résidu qui possède la valeur minimale est celui associé à la classe 1 (voir la barre en rouge de la Figure 3.3 (c)). Donc, la méthode SRC a bien réussi à classifier l'image radar d'entrée.

3.5 Conclusion

Ce chapitre a été consacré à la description du concept central de nos travaux de recherche à savoir l'introduction de la parcimonie dans la classification des images radar. Avant de mettre en exergue l'idée derrière l'intégration de la parcimonie dans les problèmes de classification, nous avons donné quelques définitions et éclaircissements pour une bonne compréhension de ce concept.

À travers le présent chapitre, nous pouvons conclure que les performances de la classification parcimonieuse dépendent fortement de la qualité de la décomposition parcimonieuse. Cette dernière est conditionnée à son rôle par le choix du dictionnaire et de l'algorithme de résolution du problème d'optimisation. Nous nous focalisons tout au long du travail réalisé à la proposition de nouveaux dictionnaires aptes à améliorer les performances de la classification parcimonieuse des images radar. Ce dictionnaire a l'exigence d'être d'une part le plus redondant possible et d'autre part ses atomes doivent être re-




FIGURE 3.3 – Résultats de classification en utilisant la méthode SRC sur (a) Une image radar de test appartenant à la classe C1. (b) Le vecteur parcimonieux obtenu $\hat{x}$. (c) Les résidus des 12 classes.

présentatifs et discriminatifs. Ainsi, nous proposons dans les chapitres 4 et 5, différents dictionnaires adaptés dans le processus de reconnaissance de cibles à partir des images radar.

FILTRAGE ATTENTIONNEL DES POINTS CARACTÉRISTIQUES SIFT ET CLASSIFICATION PARCIMONIEUSE MULTITÂCHES

Sommaire

4.1	Introduction	44
4.2	Schéma global de l'approche proposée MSKD+MSRC	44
4.3	Traitement et caractérisation des images radar par la méthode MSKD	45
4.3.1	Principe de la saillance visuelle	45
4.3.2	Principe de la méthode SIFT	49
4.3.3	Description de la méthode MSKD	52
4.4	Classification parcimonieuse multitâche	54
4.4.1	Construction du dictionnaire	55
4.4.2	Reconnaissance par une approche parcimonieuse multitâche	55
4.5	Application et résultats	56
4.5.1	Présentation de la démarche d'application et d'évaluation	56
4.5.2	Application aux images ISAR et résultats	57
4.5.3	Application aux images SAR et résultats	60
4.6	Synthèse	63

4.1 Introduction

Nous nous intéressons dans ce chapitre à une description locale des images radar en utilisant la méthode SIFT (Scale Invariant Feature Transform) [Lowe, 2004a]. Cette méthode calcule les descripteurs de points clés de l'image radar. Ces derniers sont localisés dans toute l'image radar. Cependant, nous nous intéressons seulement aux points clés localisés dans la région d'intérêt dans la phase de reconnaissance. Par conséquent, une phase de sélection s'impose. Inspirés par le travail de [Wang *et al.*, 2014] dans la recherche d'images SAR par le contenu, nous proposons d'appliquer dans un premier temps la saillance visuelle afin de localiser l'objet saillant dans l'image radar. Ensuite, les descripteurs SIFT sont calculés seulement sur l'objet saillant pour réduire le nombre de points clés décrivant l'image radar. Pour la reconnaissance de cibles, l'idée intuitive est d'appliquer la méthode SRC pour chaque descripteur SIFT. Ce principe est appelé la classification multitâche [Liao *et al.*, 2013, Zhang *et al.*, 2014].

Ce chapitre commence par la présentation du schéma global de l'approche proposée pour l'aide à la reconnaissance de cibles à partir des images radar. Ensuite, la description théorique de chaque étape de ce schéma est présentée. À la fin de ce chapitre, une évaluation quantitative et comparative de l'approche proposée en utilisant les images ISAR et les images SAR est présentée.

4.2 Schéma global de l'approche proposée MSKD+MSRC

Le schéma global de l'approche développée et appliquée pour la reconnaissance de cibles à partir des images radar est illustré par la Figure 4.1. L'architecture proposée se compose de deux étapes complémentaires. La première étape inclut la détection de la zone saillante et sa caractérisation via la méthode MSKD (Multiple Salient Keypoint Descriptors). La deuxième étape concerne la phase dédiée à la reconnaissance en utilisant la méthode de classification MSRC (Multitask Sparse Representation-based Classification). Dans ce sens et tout au long de ce chapitre, l'approche combinant les deux étapes indiquées ci-dessus sera intitulée MSKD+MSRC.

Pour caractériser les cibles dans les images radar, nous entamons une combinaison entre la méthode SIFT (*Scale-Invariant Feature Transform*) et la saillance visuelle. L'objectif derrière cette combinaison est la réduction du nombre de points clés SIFT en ne calculant que ceux localisés dans la région contenant la cible (région saillante). Cette méthodologie est appliquée sur les images de test et d'apprentissage. Les MSKD de la base d'apprentissage permettent de construire le dictionnaire du problème parcimonieux d'optimisation.

Concernant la reconnaissance de cibles, nous utilisons la méthode de classification MSRC en considérant chaque vecteur du MSKD étant une tâche. Cette méthode calcule la représentation parcimonieuse de chaque tâche en se basant sur le dictionnaire bâti dans l'étape précédente. Ensuite, elle détermine la classe de l'image radar en prenant

en considération toutes les erreurs de reconstructions parcimonieuses appelées résidus de toutes les tâches.

Nous détaillons ces étapes dans les sections 4.3 et 4.4.




FIGURE 4.1 – Schéma global de la première approche proposée et appliquée : MSKD+MSRC.

4.3 Traitement et caractérisation des images radar par la méthode MSKD

Nous rappelons que le MSKD est une combinaison de deux méthodes : saillance visuelle et SIFT. Nous décrivons ces deux méthodes dans la présente section.

4.3.1 Principe de la saillance visuelle

4.3.1.1 Attention visuelle humaine

À chaque instant, une quantité d'information très élevée parvient à l'œil humain. Cette information n'est pas traitée en totalité. C'est la raison pour laquelle l'attention est focalisée sur une partie restreinte du champ visuel. Cette focalisation permet de concentrer le regard vers une région particulière et ainsi la percevoir plus en détail. Cela est atteint par les mécanismes de l'attention visuelle issus du Système Visuel Humain (SVH). Parmi les techniques utilisées par le SVH pour sélectionner les zones les plus attirantes dans une scène, on trouve la saillance visuelle. Cette dernière représente l'information perceptuelle permettant à certaines régions ou objets de la scène observée d'attirer l'attention visuelle de l'observateur. Les auteurs dans [Nakayama et Mackeben, 1989, William, 1983] avaient émis l'hypothèse qu'au moins deux processus attentionnels du SVH influencent la focalisation attentionnelle vers une région particulière :

- **Processus bottom-up (ascendant)** : c'est un mécanisme exogène guidé uniquement par des *stimuli* captés par notre système visuel SVH. Ce processus permet de sélectionner involontairement les informations visuelles attirantes selon leurs saillances, et ce avec aucune connaissance *a priori* sur la scène observée. En effet, la saillance s'appuie uniquement sur le contenu de l'image. Par conséquent, les régions saillantes d'une image sont en principe toujours les mêmes quelque soit l'observateur.
- **Processus top-down (descendant)** : c'est un mécanisme endogène guidé par des facteurs cognitifs tels que les connaissances, les attentes et les objectifs de l'observateur. Par conséquent, ce processus fait intervenir la sémantique de la scène observée.

Le principe de fonctionnement de ces deux mécanismes de l'attention visuelle a été décrit dans [Treisman et Gelade, 1980] en présentant la théorie de l'intégration de primitives (en anglais, *Feature Integration Theory* (FIT)). Cette théorie repose sur des expériences de recherche visuelle qui quantifient le temps de réaction afin de distinguer un objet attirant (différent) parmi d'autres objets appelés distracteurs. Ces objets sont caractérisés par une seule propriété visuelle ou plusieurs à la fois. Ces propriétés peuvent être la forme, l'orientation, la couleur ou autres. Les conclusions déduites de ces expériences ont dévoilé deux sortes de recherche [Treisman et Gelade, 1980, Borji et Itti, 2013] :

- **Recherche disjonctive** : la cible possède une caractéristique visuelle différente par rapport aux distracteurs (la couleur par exemple, Cf. Figure 4.2 (a)). Dans ce cas de figure, quelque soit le nombre de distracteurs, le temps de réaction nécessaire pour localiser la cible sera constant. La cible se distingue facilement de son voisinage, on dit qu'elle saute aux yeux (effet *Pop-out*). Cette distinction est effectuée d'une façon parallèle. Ce type de recherche peut être donc associé au processus *bottom-up*.
- **Recherche conjonctive** : la cible est une combinaison de caractéristiques visuelles (la couleur et l'orientation par exemple, Cf. Figure 4.2 (b)). Dans ce cas-là, le temps de réaction nécessaire pour localiser la cible augmente linéairement avec le nombre de distracteurs. Ceci dit, chaque objet doit être examiné séquentiellement. Ce type de recherche peut être donc associé au processus *top-down*.

La théorie FIT atteste que l'information visuelle interceptée par nos yeux est décomposée au niveau du cortex visuel en attributs élémentaires. Ces différents attributs subissent un traitement parallèle et sont représentés dans des cartes d'attributs spécifiques. Ces cartes sont par la suite fusionnées en une carte maîtresse (en anglais, *Master Saliency Map*). Les zones mises en évidence sur cette carte correspondent aux zones saillantes.

Les études réalisées sur l'attention visuelle dans différents domaines à l'instar de la psychologie, la neurophysiologie ou la psychophysique, ont évoqué la curiosité de la communauté de traitement d'images. Ces études ont été parmi les principales sources d'inspiration pour développer des systèmes automatiques proches ou similaires au fonctionnement du SVH. Plus précisément, pour les chercheurs, l'un des défis majeurs porte




FIGURE 4.2 – Exemples de stimuli utilisés dans des tâches de recherche de cibles [Wolfe *et al.*, 2010] . (a) La cible a une couleur différente des autres distracteurs (impossible de ne pas la voir). On dit que la recherche est disjonctive et par conséquent le processus est de type *bottom-up*. (b) La cible partage plusieurs attributs visuels avec les autres distracteurs : elle a la même couleur que les distracteurs rouges ainsi que la même orientation verticale que les distracteurs verts. La recherche dans ce cas est dite conjonctive et le processus est dit *top-down*.

sur la proposition de méthodes aptes à localiser les zones les plus attirantes sur une image. Les premières études ont montré que les processus *bottom-up* sont plus rapides et excèdent les processus *top-down* qui sont plus lents à mettre en œuvre. En plus, la connaissance *a priori* de la scène n'est pas toujours disponible. Pour cette raison, la plupart des méthodes de saillance visuelle est basée sur le processus *bottom-up*. Ces méthodes ont connu un grand intérêt dans la détection et la localisation d'objets [Peng *et al.*, 2017, Diao *et al.*, 2016, Wang *et al.*, 2018, Gao *et al.*, 2017b] , la recherche d'images par le contenu [Feng *et al.*, 2010, Wu *et al.*, 2017] , la classification et la segmentation des images [Siagian et Itti, 2007, Cooley *et al.*, 2017]. Frintrop dans [Frintrop, 2011] affirme qu'un système d'attention visuelle est indispensable dans ces domaines afin de réduire l'espace de recherche ainsi que la complexité de calcul. Ces systèmes peuvent être considérés comme des détecteurs de régions d'intérêts.

Pour modéliser et simuler l'attention visuelle, plusieurs systèmes d'attention endogène se sont succédé [Borji et Itti, 2013]. Ils se basent principalement sur la théorie FIT. L'un des plus populaires et le plus utilisé de nos jours est celui proposé par [Itti *et al.*, 1998].

4.3.1.2 Modèle de saillance d'Itti

Le modèle d'Itti [Itti *et al.*, 1998] a été proposé en 1998 et a fait révolutionner les axes de recherche traitant la saillance visuelle. Il est dérivé essentiellement du modèle présenté

dans [Koch et Ullman, 1987], il est décrit par les étapes suivantes :

1. **Filtrage linéaire** : dans cette étape le modèle calcule plusieurs cartes d'attributs :
 - Une carte d'intensité :

$$I = \frac{(r + g + b)}{3} \quad (4.1)$$

avec (r, g, b) sont les composantes couleurs de l'image : rouge, vert et bleu.

- Quatre cartes de couleur sont considérées (rouge R , vert G , bleu B et jaune Y) :

$$R = r - \frac{(g + b)}{2} \quad (4.2)$$

$$G = g - \frac{(r + b)}{2} \quad (4.3)$$

$$B = b - \frac{(r + g)}{2} \quad (4.4)$$

$$Y = \frac{(r + g)}{2} - \frac{|r - g|}{2} - b \quad (4.5)$$

- Quatre cartes d'orientation considérées : obtenues en appliquant les filtres de Gabor sur la carte d'intensité. Les orientations choisies sont : $\omega \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$.

Après le calcul des différentes cartes d'attributs, une représentation multi-échelles est construite via l'application des pyramides Gaussiennes avec 9 niveaux de décompositions sur chaque composante.

2. **Différence centre-voisins et normalisation** : cette étape vise à calculer les cartes caractéristiques (en anglais, *Feature maps*) correspondantes à chaque composante. Cela est établi en appliquant une différence centre-voisins entre les échelles fines (centre) et les échelles grossières (voisins). Les centres correspondent aux pixels à l'échelle $c \in \{2, 3, 4\}$ et les voisins sont les pixels de l'échelle $s = c + z, z \in \{3, 4\}$. Cette différence notée $\ominus$ est obtenue par l'interpolation à l'échelle la plus fine et la soustraction point par point. Elle est calculée comme suit pour les différents attributs :

- L'intensité :

$$I(c, s) = |I(c) \ominus I(s)| \quad (4.6)$$

Par conséquent, on obtient 6 cartes caractéristiques pour l'intensité.

- La couleur :

$$\begin{aligned} RG(c, s) &= |(R(c) - G(c)) \ominus (G(s) - R(s))| \\ BY(c, s) &= |(B(c) - Y(c)) \ominus (Y(s) - B(s))| \end{aligned} \quad (4.7)$$

Comme résultat, 12 cartes caractéristiques sont calculées pour la couleur.

- L'orientation :

$$O(c, s, \omega) = |O(c, \omega) \ominus O(s, \omega)| \quad (4.8)$$

Cela permet de générer 24 cartes caractéristiques pour l'orientation.

Au total, $6 + 12 + 24 = 42$ cartes caractéristiques sont obtenues. Celles-ci sont ensuite normalisées par l'opérateur $\mathcal{N}$ (Cf. l'équation (4.9)) pour renforcer les cartes qui ne contiennent qu'un petit nombre de zones saillantes :

$$\mathcal{N}(I) = (M - \bar{p})^2 \quad (4.9)$$

avec M représente le maximum global de la carte et $\bar{p}$ est la moyenne.

3. **Combinaison et normalisation** : les cartes de caractéristiques calculées auparavant sont combinées et normalisées dans cette étape en trois cartes de visibilité (en anglais, *Conspicuity maps*). Une pour chaque attribut ($\bar{I}$ pour l'intensité, $\bar{C}$ pour la couleur et $\bar{O}$ pour l'orientation). Ces cartes sont obtenues par une addition *across-scale* " $\oplus$ " qui additionne les cartes point par point comme suit :

— L'intensité :

$$\bar{I} = \oplus_{c=2}^4 \oplus_{s=c+3}^{s=c+3} N(I(c, s)) \quad (4.10)$$

— La couleur :

$$\bar{C} = \oplus_{c=2}^4 \oplus_{s=c+3}^{s=c+3} [N(RG(c, s)) + N(BY(c, s))] \quad (4.11)$$

— L'orientation :

$$\bar{O} = \sum_{\omega \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}} N(\oplus_{c=2}^4 \oplus_{s=c+3}^{s=c+3} N(O(c, s, \omega))) \quad (4.12)$$

4. **Combinaison linéaire** : Par la suite, les trois cartes de visibilité sont normalisées et additionnées pour obtenir une carte de saillance finale :

$$S = \frac{1}{3} (\mathcal{N}(\bar{I}) + \mathcal{N}(\bar{C}) + \mathcal{N}(\bar{O})) \quad (4.13)$$

Finalement, pour une finalité de génération des différentes focalisations attentionnelles, un réseau *Winner Takes All (WTA)* est utilisé. Ce réseau sélectionne la zone la plus saillante dans l'image. Puis, une inhibition locale est appliquée pour ne pas considérer de nouveau cette zone et ainsi trouver la suivante zone saillante.

Un exemple de deux cartes de saillance générées par cette méthode pour une image ISAR et une image SAR est donné par la Figure 4.3. Les images radar utilisées dans le travail réalisé ne contiennent qu'une seule cible radar. Par conséquent, le modèle d'Itti a bien réussi à localiser la région d'intérêt dans l'image radar considérée qui est représentée dans notre cas par une cible. Une fois la zone saillante est détectée, nous calculons sur cette zone les points clés dont le principe est présenté dans la section suivante.

4.3.2 Principe de la méthode SIFT

La méthode SIFT (Scale Invariant Feature Transform) a été développée par David Lowe [Lowe, 2004a] pour l'extraction de descripteurs locaux à partir d'une image. Les




FIGURE 4.3 – Exemple de cartes de saillance des images radar. Première colonne à gauche : images ISAR et SAR. Deuxième colonne à droite : leurs cartes de saillance obtenues par la méthode d'Itti.

descripteurs extraits sont invariants à différentes transformations à l'instar de la translation, la rotation, le changement d'échelle et l'illumination. De plus, ils sont robustes au bruit. Par conséquent, cette méthode a été utilisée dans plusieurs applications comme la reconnaissance de visages [Liao *et al.*, 2013], la biométrie [Ladoux *et al.*, 2009] et la recherche d'images par le contenu [Zheng *et al.*, 2017] et également utilisée en télédétection [Srinivas *et al.*, 2011, Knee *et al.*, 2011, Agrawal *et al.*, 2015, Dellinger *et al.*, 2015, Xiang *et al.*, 2018]. Généralement, la méthode SIFT est composée de quatre étapes : la détection d'extrema dans l'espace des échelles, la localisation de points clés, l'assignation d'orientation et la description de points clés. Nous présentons ces étapes dans ce qui suit.

4.3.2.1 Détection d'extrema dans l'espace des échelles

L'image à caractériser est en premier lieu transformée dans un espace discret appelé espace des échelles (en anglais, *scale space*). Cela est atteint en convoluant (*) l'image $I(x, y)$ avec un filtre Gaussien $G(x, y, \sigma)$ de paramètre d'échelle σ :

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (4.14)$$

avec x et y sont les coordonnées cartésiennes de l'image I . Le filtre Gaussien $G(x, y, \sigma)$ est donné par :

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (4.15)$$

L'objectif de cette convolution est le lissage de l'image originale à différentes échelles, et donc extraire les petits détails de l'image.

Après cela, des différences de Gaussiennes (en anglais, DoG : *Difference of Gaussians*) sont calculées entre deux échelles proches séparées par un facteur constant q :

$$\begin{aligned} DoG(x, y, \sigma) &= (G(x, y, q\sigma) - G(x, y, \sigma)) * I(x, y) \\ &= L(x, y, q\sigma) - L(x, y, \sigma) \end{aligned} \quad (4.16)$$

Nous notons que les images successives ayant les mêmes tailles sont appelées octaves. La valeur du paramètre d'échelle varie d'une échelle à une autre. Pour obtenir la nouvelle valeur de ce paramètre pour une échelle donnée, on multiplie le paramètre d'échelle initiale σ_0 par le facteur q qui est égal pratiquement à $2^{\frac{o+l}{L}}$ (avec o est l'indice de l'octave, l représente l'indice de l'échelle et L désigne le nombre d'échelles par octave). De cette manière, nous obtenons une pyramide Gaussienne dont la base est l'image originale. Dans cette pyramide, un sous-échantillonnage de 2 est appliqué sur l'image une fois que le paramètre d'échelle $q\sigma$ atteint une puissance de 2.

Un pixel dans le DoG est considéré comme point clé s'il est l'extrema (le maximum ou le minimum local) de ses 26 voisins (8 voisins de son échelle, 9 voisins de l'échelle supérieure et 9 voisins de l'échelle inférieure).

4.3.2.2 Localisation de points clés

Les points clés obtenus dans l'étape précédente sont ensuite filtrés en éliminant les points de faibles contrastes ou ceux situés sur des arêtes de contours faibles.

Pour filtrer les points de faible contraste, un seuillage est appliqué :

$$| DoG | > th \quad (4.17)$$

Les points pour lesquels le DoG n'atteint pas le seuil th pour une échelle donnée sont supprimés. Ce principe est connu dans la littérature sous le nom « détecteur de Harris-Laplace » (ou critère de Harris) [Mikolajczyk et Schmid, 2001, Mikolajczyk et Schmid, 2004].

Afin d'éliminer les points situés sur des arêtes de contours faibles, la matrice Hessienne est utilisée. Elle est définie comme suit :

$$H = \begin{bmatrix} D_{xx} & D_{xy} \\ D_{yx} & D_{yy} \end{bmatrix} = \begin{bmatrix} \frac{\partial^2 D}{\partial x^2} & \frac{\partial^2 D}{\partial x \partial y} \\ \frac{\partial^2 D}{\partial y \partial x} & \frac{\partial^2 D}{\partial y^2} \end{bmatrix} \quad (4.18)$$

La méthode SIFT supprime les points satisfaisants le critère de l'équation (4.19) :

$$\frac{Tr(H)^2}{Det(H)} = \frac{(r+1)^2}{r} \geq \frac{(r_{th}+1)^2}{r_{th}} \quad (4.19)$$

avec $Tr(.)$ et $Det(.)$ représentent la trace et le déterminant de la matrice et r est le rapport entre la plus grande et la plus petite valeur des valeurs propres de H .

4.3.2.3 *Assignment d'orientation*

Les deux premières étapes de la méthode SIFT ont permis d'affecter au point clé une position spatiale $(\{x, y\})$. L'orientation affectée à un point clé est calculée lors de cette étape. Pour ce faire, l'auteur dans [Lowe, 2004a] a considéré un voisinage. Pour chaque pixel $L_{x,y}$ de cette zone de voisinage, l'amplitude du gradient m ainsi que son orientation or sont calculées comme suit :

$$m = \sqrt{(L_{x+1,y} - L_{x-1,y})^2 + (L_{x,y+1} - L_{x,y-1})^2} \quad (4.20a)$$

$$or = \tan^{-1} \left(\frac{L_{x,y+1} - L_{x,y-1}}{L_{x+1,y} - L_{x-1,y}} \right) \quad (4.20b)$$

Ainsi, l'histogramme des orientations est calculé. Chaque pixel est ensuite pondéré par son amplitude et par une fenêtre Gaussienne. Cet histogramme comporte 36 intervalles de 10 degrés d'angles chacun couvrant 360° d'orientations possibles. L'orientation du point clé correspond au pic de l'histogramme des orientations pour des valeurs supérieures à 80% de la valeur maximale. Une fois l'orientation d'un point clé est obtenue, un descripteur clé est calculé dont le principe est présenté en ce qui suit.

4.3.2.4 *Description de points clés*

L'objectif de cette étape est de calculer un descripteur pour chaque point clé. Cela est réalisé en considérant une région de 16×16 pixels autour du point clé. Cette région est subdivisée par la suite en 16 zones de 4×4 pixels chacune. Pour chaque zone, un histogramme de 8 intervalles est calculé. Par conséquent, un descripteur final de dimension $4 \times 4 \times 8 = 128$ valeurs est obtenu. Nous illustrons dans la Figure 4.4 un exemple de points clés SIFT détectés sur l'exemple d'une image ISAR et une image SAR.

Nous rappelons à ce stade, que nous avons proposé d'utiliser la zone saillante comme la zone sur laquelle l'extraction de points clés SIFT est réalisée.

4.3.3 **Description de la méthode MSKD**

En s'appuyant sur la Figure 4.4, nous pouvons constater que l'application de la méthode SIFT sur toute l'image génère un grand nombre de points clés. Ceux qui sont localisés dans l'arrière-plan des images radar ne présentent pas une information cruciale pour la caractérisation de la cible radar et risquent d'engendrer des erreurs dans la phase de classification. Pour remédier à cela, nous proposons la méthode MSKD qui combine la méthode SIFT et la saillance visuelle comme mentionné auparavant. Plus précisément, nous appliquons tout d'abord le modèle Itti sur l'image radar afin d'obtenir la carte de saillance qui localise la région la plus attirante dans les images radar. Cette région correspond bien à la zone d'intérêt (zone de l'image dans laquelle se situe la cible) (Cf. Figure 4.3). Cette carte de saillance est exploitée comme un masque pour segmenter l'image radar en deux régions : l'arrière-plan et la région contenant la cible. Un exemple du résultat de cette




FIGURE 4.4 – Exemple de points clés SIFT des images radar. Première colonne à gauche : images ISAR et SAR. Deuxième colonne à droite : leurs points clés SIFT détectés.

segmentation est donné dans la troisième colonne de la Figure 4.1. À partir de l'image radar segmentée, nous calculons les points clés SIFT. De cette manière, les points clés localisés dans l'arrière-plan de l'image radar ne sont pas calculés comme illustré dans la troisième colonne (entièrement à droite) de la Figure 4.5.

Au final, chaque image radar est décrite par sa signature descriptive représentée par la matrice des descripteurs $\text{MSKD} \in \mathbb{R}^{m \times k'}$ donnée par :

$$\text{MSKD} = \begin{matrix} & \text{SKP}_1 & \dots & \text{SKP}_{k'} \\ \begin{matrix} 1 \\ \vdots \\ m \end{matrix} & \begin{bmatrix} v_{1,1} & \dots & v_{k',1} \\ \vdots & \ddots & \vdots \\ v_{1,m} & \dots & v_{k',m} \end{bmatrix} \end{matrix} \quad (4.21)$$

avec k' est le nombre de points clés saillants (SKP) dans l'image radar d'apprentissage et $m = 128$ est la taille du descripteur de chaque SKP.

Nous avons présenté dans les sections précédentes de ce chapitre, la méthode proposée (MSKD) qui est utilisée pour caractériser chaque image radar (ISAR et SAR) et ainsi préparer les données à la phase de classification que nous présentons dans la section suivante.




FIGURE 4.5 – Distributions de points clés SIFT. Première colonne à gauche : images ISAR et SAR. Deuxième colonne au milieu : distribution de points clés SIFT sur la totalité des images. Troisième colonne à droite : distribution de points clés SIFT sur la zone d'intérêt (méthode MSKD).

4.4 Classification parcimonieuse multitâche

Dans la littérature, la méthode de classification la plus intuitive des descripteurs SIFT est le matching. Son principe est très proche de la méthode de classification KPPV. Nous proposons dans ce travail d'adopter une approche parcimonieuse pour classer les descripteurs SIFT. Cela est réalisée en utilisant la méthode MSRC (Multitask Sparse Representation-based Classification).

Dans la phase d'apprentissage, nous construisons le dictionnaire intégrant tous les MSKD des images radar de la base d'apprentissage. Pour classer une image inconnue (image de la base de test) caractérisée par la méthode MSKD, nous résolvons un problème d'optimisation qui code chaque descripteur appelé task (une colonne de la matrice MSKD) en utilisant un vecteur parcimonieux. Après cela, nous calculons les résidus de toutes les tâches avec les vecteurs parcimonieux correspondant. Ces résidus sont ensuite additionnés (Cf. Figure 4.1). Finalement, la classe qui possède le résidu minimum est affectée à l'image radar de test.

4.4.1 Construction du dictionnaire

Le dictionnaire $A \in \mathbb{R}^{m \times n}$ est obtenu en concaténant tous les MSKD des images d'apprentissage :

$$\begin{aligned} A &= [\text{MSKD}_1, \dots, \text{MSKD}_s] \\ &= \begin{matrix} & \text{SKP}_1 & \dots & \text{SKP}_n \\ \begin{matrix} 1 \\ \vdots \\ m \end{matrix} & \begin{bmatrix} v_{1,1} & \dots & v_{n,1} \\ \vdots & \ddots & \vdots \\ v_{1,m} & \dots & v_{n,m} \end{bmatrix} \end{matrix} \end{aligned} \quad (4.22)$$

avec s est le nombre des images radar d'apprentissage et n est le nombre de SKP dans toutes les images radar de la base d'apprentissage.

4.4.2 Reconnaissance par une approche parcimonieuse multitâche

Le calcul des descripteurs locaux ($Y \in \mathbb{R}^{m \times k}$) d'une image radar de test en utilisant la méthode MSKD donne lieu à une matrice de descripteurs :

$$\begin{aligned} Y &= [y_1, \dots, y_k] \\ &= \begin{matrix} & \text{SKP}_1 & \dots & \text{SKP}_k \\ \begin{matrix} 1 \\ \vdots \\ m \end{matrix} & \begin{bmatrix} u_{1,1} & \dots & u_{n,1} \\ \vdots & \ddots & \vdots \\ u_{1,m} & \dots & u_{k,m} \end{bmatrix} \end{matrix} \end{aligned} \quad (4.23)$$

Pour reconnaître Y par une approche parcimonieuse, nous utilisons plusieurs SRC, chacun correspond à une tâche. Ainsi, la représentation linéaire de Y est exprimée comme suit (Cf. Figure 4.6) :

$$Y = AX \quad (4.24)$$

avec $X = (x_1, \dots, x_n) \in \mathbb{R}^{n \times k}$ est une matrice des coefficients parcimonieux. Pour la calculer, le problème d'optimisation à résoudre est donné par :

$$\hat{X} = \underset{X}{\operatorname{argmin}} \sum_{i=1}^k \|x_i\|_1 \quad \text{sous la contrainte} \quad \|Y - AX\|_2 \leq \epsilon \quad (4.25)$$

l'équation (4.25) représente un problème multitâche car X et Y contiennent plusieurs atomes (colonnes). Cela peut être transformé en k ℓ_1 problèmes d'optimisation convexe, chacun pour chaque y_i (chaque tâche) :

$$\hat{x}_i = \underset{x_i}{\operatorname{argmin}} \|x_i\|_1 \quad \text{sous la contrainte} \quad \|y_i - Ax_i\|_2 \leq \epsilon \quad (4.26)$$

Après avoir obtenu la matrice parcimonieuse $\hat{X} = (\hat{x}_1, \dots, \hat{x}_k) \in \mathbb{R}^{n \times k}$, la classe de Y est celle qui produit le résidu le plus faible parmi les n_c classes. Nous notons ici qu'une fusion




FIGURE 4.6 – Schéma de décomposition du signal multi-dimensionnel Y dans le dictionnaire A via la matrice parcimonieuse X . Les cases en couleurs signifient les coefficients non nuls tandis que celles en blancs représentent les coefficients nuls.

de type sommation est appliquée sur les résidus de toutes les différentes tâches :

$$\begin{aligned}
 \text{classe}(Y) &= \underset{c}{\operatorname{argmin}} \sum_{i=1}^k r_c(y_i) \\
 &= \underset{c}{\operatorname{argmin}} \sum_{i=1}^k \|y_i - \hat{y}_i\|_2 \\
 &= \underset{c}{\operatorname{argmin}} \sum_{i=1}^k \|y_i - A\delta_c(\hat{x}_i)\|_2
 \end{aligned} \tag{4.27}$$

avec $c = \{1, \dots, nc\}$ sont les labels des classes et $\delta_c : \mathbb{R}^n \rightarrow \mathbb{R}^n$ une fonction qui sélectionne dans le vecteur d'entrée les coefficients associés à la classe c .

4.5 Application et résultats

4.5.1 Présentation de la démarche d'application et d'évaluation

Nous évaluons dans cette partie les performances de l'approche développée. Cette évaluation est réalisée en considérant des images radar (ISAR et SAR). Les résultats de reconnaissance sont donnés avec la fourniture du taux de reconnaissance et le temps d'exécution de l'approche. Pour ce faire, nous testons différentes méthodes sur les deux bases de données d'images radar décrites dans la sous-section 2.3.3.

Afin d'établir une comparaison équitable et objective, nous avons implémenté trois autres méthodes qui sont pratiquement proches de celle développée dans ce travail. La première méthode est basée sur l'utilisation de SIFT sur toute l'image avec la méthode

du matching (SIFT+matching) pour la classification. La deuxième méthode consiste à utiliser le MSKD (points clés SIFT localisés dans la région d'intérêt) comme entrée du matching (MSKD+matching). Quant à la troisième méthode, elle combine les méthodes SIFT appliquée sur la globalité de chaque image radar et MSRC (SIFT+MSRC). Pour les différentes méthodes, les descripteurs SIFT sont calculés en utilisant 4 octaves et 5 niveaux par octave. Le paramètre d'échelle σ_0 a été initialisé à 1.6. Les seuils th et r_{th} utilisés pour éliminer les points clés instables valent respectivement 0.03 et 10. En gros, les différentes valeurs des étapes SIFT adoptées par Lowe [Lowe, 2004a] ont été maintenues dans ce travail.

Toutes les méthodes ont été implémentées sous Matlab 2016 avec un processeur Intel CPU i5 de 3.10 GHz et 24 Go de mémoire.

4.5.2 Application aux images ISAR et résultats

Nous étudions dans la Figure 4.7 l'influence du nombre d'atomes dans le dictionnaire (taille de la base d'apprentissage) sur le taux de bonne reconnaissance obtenu sur la base de données d'images ISAR. Pour l'évaluation, nous avons utilisé une validation croisée de type *Hold-Out Cross-Validation*. Ainsi, nous avons varié la taille de la base d'apprentissage avec les rapports de : 10%, 20%, 30% et 40% de la base d'images complète qui représente respectivement 195, 390, 585 et 780 atomes. Le reste des images ISAR est utilisé pour le test. Cela correspond respectivement à 1749, 1554, 1359 et 1164 images ISAR dans la base de test.

Nous pouvons constater d'après la Figure 4.7 que toutes les méthodes sont sensibles aux nombres d'atomes dans le dictionnaire (la taille de la base d'apprentissage). Le taux de bonne classification croît avec l'augmentation du nombre d'atome. La Figure 4.7 prouve aussi que la méthode proposée (MSKD+MSRC) dépasse les autres méthodes en terme de taux de reconnaissance pour les différents nombres d'atomes considérés. En plus, en comparant les méthodes de classification du matching et MSRC pour reconnaître la matrice MSKD, il est observé qu'en diminuant le nombre d'atomes, le taux de reconnaissance de MSKD+matching décroît plus rapidement que celui donné par la méthode proposée.

Dans la suite de l'évaluation de l'approche proposée, nous adoptons un nombre d'atomes égal à 780 (40% de la base de données pour l'apprentissage). Par conséquent, la base de test se compose de 1164 images ISAR tandis que la base d'apprentissage contient 780 images ISAR. Sous cette configuration, nous comparons dans le Tableau 4.1 la méthode proposée avec les autres méthodes tout en mettant l'accent sur le nombre de points clés détectés. Plusieurs observations peuvent être déduites. Tout d'abord, la méthode SIFT combinée avec la méthode du matching donne les résultats les plus faibles. Cela s'explique par la localisation de la plupart de points clés dans l'arrière-plan des images ISAR ce qui engendre des erreurs de classification (Cf. Figure 4.5). Ces derniers ne sont pas nécessaires pour caractériser l'images ISAR comme illustré par la Figure 4.5. D'autre part, le nombre important de points clés engendre un temps de calcul important dans la méthode du mat-




FIGURE 4.7 – Variation du taux de reconnaissance en fonction du nombre d'atomes dans le dictionnaire pour le cas des images ISAR.

ching. En revanche, le MSKD permet d'améliorer les taux de bonne reconnaissance grâce à la concentration de points clés dans la zone d'intérêt. Par conséquent, un nombre réduit de points clés permet ainsi à caractériser l'image ISAR. Par exemple, avec un nombre minimale de points clés de 23 559 (ce qui correspond à 17.83% du 420 027 de points clés initiaux) permet d'avoir une amélioration dans le taux de reconnaissance de 5.29% et 2.73% respectivement. Cette amélioration montre bien l'intérêt du filtrage adopté de points clés SIFT. Ensuite, la classification avec MSRC donne des résultats meilleurs en comparaison avec la méthode du matching que ce soit pour les descripteurs SIFT ou MSKD. Cela peut être expliqué par le fait que la parcimonie multitâche des descripteurs SIFT des images ISAR contribue à l'amélioration du taux de reconnaissance.

TABLE 4.1 – Taux de reconnaissance (%) des images ISAR pour différentes méthodes en comparaison avec la méthode proposée (MSKD+MSRC).

Méthodes	SIFT+matching	MSKD+matching	SIFT+MSRC	MSKD+MSRC (méthode proposée)
Taux de reconnaissance	82.61	87.90	90.92	93.65
Nombre de points clés	420 027	23 559	420 027	23 559

Nous présentons dans la Figure 4.8 les matrices de confusion obtenues d'une part en utilisant la méthode proposée, et d'autre part avec les autres méthodes. Nous constatons que la méthode proposée présente les meilleurs taux de classification que les autres méthodes pour les différentes classes à l'exception des cibles F15, Rafale et F18. En plus de ça, elle atteint un taux de reconnaissance de 100% pour cinq classes : F117, F104, A10, F14 et Mig29. Le taux de reconnaissance global obtenu avec la méthode proposée

est de 93.65%, soit 11.04%, 5.75% et 2.73% beaucoup meilleur que celui obtenu avec les méthodes SIFT + matching, MSKD + matching et SIFT + MSRC respectivement. Ces performances montrent bien que la combinaison du MSKD avec le classifieur parcimonieux multitâche a été bénéfique et d'intérêt pour la reconnaissance de cibles à partir des images ISAR.




FIGURE 4.8 – Matrices de confusion obtenues pour les différentes méthodes appliquées aux images ISAR : (a) MSKD+MSRC ; (b) SIFT+MSRC ; (c) MSKD+matching ; (d) SIFT+matching

Une comparaison des temps de calcul nécessaires pour l'exécution de la méthode proposée ainsi que les autres méthodes a été menée aussi comme il est montré dans le Tableau 4.2. Dans ce tableau, nous présentons le temps d'exécution moyen correspondant à chaque image ISAR de la base de test pour les étapes de traitement (sélection de la zone d'intérêt dans notre cas), d'extraction de caractéristiques et de reconnaissance. Ce temps d'exécution moyen correspond à celui nécessaire pour traiter une seule image de

la base de test. En additionnant le temps d'exécution des trois étapes, nous obtenons le temps d'exécution moyen pour chaque méthode. En analysant ces temps de calcul, nous constatons que la méthode SIFT est extrêmement consommatrice en temps de calcul du fait qu'elle intègre le calcul des descripteurs de points clés de toute la globalité de l'image ISAR. Malgré que le filtrage adopté réduit le temps de calcul de la phase de l'extraction de caractéristiques (caractérisation de points clés), il nécessite un temps de calcul de 0.27 secondes. D'autre part, un temps de calcul très important est exigé afin de reconnaître les descripteurs SIFT avec les méthodes du matching et MSRC. Cependant, ce temps est considérablement réduit avec l'utilisation du MSKD. Ensuite, la méthode MSRC demande plus de temps d'exécution que la méthode du matching. Ceci peut s'expliquer par le temps consommé pour la résolution du problème d'optimisation convexe pour chaque tâche (chaque point clé). Néanmoins, la méthode MSRC contribue à améliorer les performances de reconnaissance surtout en la combinant avec la méthode MSKD. Nous notons aussi que la méthode SIFT+MSRC présente un temps de calcul 2.30 fois supérieur à celui de la méthode proposée.

TABLE 4.2 – Temps d'exécution (s) des images ISAR pour différentes méthodes en comparaison avec la méthode proposée (MSKD+MSRC).

Méthodes	SIFT+matching	MSKD+matching	SIFT+MSRC	MSKD+MSRC (méthode proposée)
Traitement	0	0.27	0	0.27
Extraction de caractéristiques	0.24	0.08	0.24	0.08
Reconnaissance	5.72	2.22	414.43	180.07
Total	5.96	2.57	414.67	180.42

4.5.3 Application aux images SAR et résultats

Comme dans le cas précédent des images ISAR, nous comparons quantitativement dans le Tableau 4.3, les résultats obtenus en utilisant la méthode proposée avec ceux obtenus à l'aide des trois autres méthodes. La comparaison a été effectuée en considérant différentes versions de la base de données d'images MSTAR. Les images SAR de cette base de données sont déjà partitionnées en base d'apprentissage et en base de test (Cf. sous-section 2.3.3.2). Comme nous pouvons le remarquer (Cf. Tableau 4.3), en utilisant la même méthode de classification, la méthode MSKD avec un petit nombre de points clés donne de meilleurs résultats de reconnaissance en comparaison avec la méthode SIFT. Cela montre, comme précédemment, que les points clés SIFT ne sont pas tous utiles pour caractériser l'image SAR, ceci est illustré par la Figure 4.5. D'où le gain obtenu en combinant la saillance visuelle et la méthode SIFT. De plus, l'utilisation du SRC multi-tâche (MSRC) conduit à une amélioration importante par rapport à la méthode du matching grâce aux vecteurs parcimonieux extraits de chaque tâche de la matrice des descripteurs obtenue par les méthodes SIFT et MSKD.

TABLE 4.3 – Taux de reconnaissance (%) des images SAR pour différentes méthodes en comparaison avec la méthode proposée (MSKD+MSRC).

Méthodes	SIFT+matching		MSKD+matching	
	Taux de reconnaissance	Nombre de points clés	Taux de reconnaissance	Nombre de points clés
SOC	45.18	183 963	47.83	35 459
EOC-1	44.40	69 962	67.32	15 751
EOC-2 (15°)	61.49	66 124	66.54	11 874
EOC-2 (30°)	48.08	71 091	53.50	12 974
EOC-2 (45°)	33.33	66 306	43.82	12 982
Méthodes	SIFT+MSRC		MSKD+MSRC (méthode proposée)	
	Taux de reconnaissance	Nombre de points clés	Taux de reconnaissance	Nombre de points clés
SOC	73.05	183 963	80.35	35 459
EOC-1	70.84	69 962	84.54	15 751
EOC-2 (15°)	70.63	66 124	84.18	11 874
EOC-2 (30°)	49.42	71 091	68.58	12 974
EOC-2 (45°)	37.34	66 306	36.32	12 982

La version SOC de la base MSTAR reste un grand défi pour effectuer la reconnaissance de cibles radar terrestres à partir des images radar. Ceci à cause d’une part du grand nombre d’images SAR existantes et d’autre part à cause du nombre important de classes qui est de 10 (Cf. la sous-sous-section 2.3.3.3). En appliquant la méthode proposée sur cette version de la base de données MSTAR, nous obtenons un taux de reconnaissance de 80.35% qui est 35.17%, 32.52% et 7.3% supérieur à celui donné par les méthodes SIFT + matching, MSKD + matching et SIFT + MSRC. Les matrices de confusion obtenues en utilisant les différentes méthodes pour cette version d’images SAR sont données par la Figure 4.9. On peut noter que la méthode proposée confond les classes BMP2, BRDM2 et BTR70 car elles sont issues du même type de cibles terrestres qui correspond à un véhicule de transport de troupes. En plus, la méthode n’a pas pu reconnaître correctement la classe BMP2. Cependant, elle possède le taux de reconnaissance global le plus élevé pour les dix classes en comparaison avec les résultats obtenus avec les autres méthodes.

Concernant la version EOC-1 (variation de configuration) de la base de données MSTAR, la méthode proposée atteint un taux de reconnaissance de 84.54%. Il s’agit d’une amélioration de 40.14%, 17.22% et 13.7% par rapport aux autres méthodes concurrentes. Le Tableau 4.4 présente les taux de reconnaissance par classe obtenus avec les différentes méthodes testées sur la version EOC-1. Nous remarquons que les taux de reconnaissances des classes BMP2 et T72 sont inférieurs à ceux de la classe BTR70 sauf dans le cas de la méthode SIFT+MSRC. Cela est dû au fait que ces deux classes contiennent plusieurs variantes dans la base de test qui ne sont pas présentes dans la base d’apprentissage. Nous notons également que la méthode proposée (MSKD+MSRC) donne des taux de reconnaissance remarquables sur les classes BTR70 et T72. Cependant, elle donne un taux de reconnaissance faible pour la classe BMP2. D’autre part, la méthode SIFT + matching n’a pas pu reconnaître aucune image de la classe BTR70.

Pour la version EOC-2 (variation des angles de dépression) de la base de données




FIGURE 4.9 – Matrices de confusion pour les différentes méthodes sur la base de données MSTAR sous les conditions SOC : (a) MSKD+MSRC ; (b) SIFT+MSRC ; (c) MSKD+matching ; (d) SIFT+matching.

MSTAR, le taux de reconnaissance se dégrade brusquement lorsque l'angle de dépression augmente, et cela pour toutes les méthodes. Cette dégradation est due à la différence entre les angles de dépression utilisés pour l'apprentissage et pour le test. Plus précisément, l'utilisation des angles de dépression de 30° et de 45° représente respectivement une différence de 13° et 28° par rapport aux images de test acquises avec un angle de 17° . Par exemple, la méthode proposée donne des taux réduits passant de 84.18% à 68.58% ou à 36.32% en augmentant l'angle de dépression de la base de test. Nous notons aussi que la méthode proposée atteint le plus grand taux de reconnaissance en utilisant des angles de dépression de 15° et 30° . Cependant, les méthodes SIFT+matching et MSKD+mathing fonctionnent mieux pour l'angle de dépression de 45° .

Le Tableau 4.5 montre les matrices de confusions obtenues avec toutes les méthodes sous la

TABLE 4.4 – Comparaison entre les matrices de confusion (%) obtenue avec la méthode proposée (MSKD+MSRC) et avec les autres méthodes dans le cas de la base de données MSTAR sous les conditions EOC-1 (variation des configurations).

	SIFT+matching (44.40)			MSKD+matching (67.32)			SIFT+MSRC (70.84)		
	BMP2	BTR70	T72	BMP2	BTR70	T72	BMP2	BTR70	T72
BMP2	80.58	0	19.42	52.98	5.96	41.06	82.15	10.36	7.49
BTR70	53.57	0	46.42	10.20	82.14	7.65	17.28	60.13	22.59
T72	77.14	0	22.85	20.27	2.92	76.80	12.06	17.69	70.25
				MSKD+MSRC (méthode proposée) (84.54)					
				BMP2	BTR70	T72			
				BMP2	72.06	8.35	19.59		
				BTR70	1.02	98.98	0		
				T72	6.35	1.37	92.26		

version EOC-2 avec différents angles de dépression. On peut noter que la méthode proposée donne un taux de reconnaissance équilibré par classe avec des erreurs de classifications faibles. Quant à l'utilisation d'un angle de dépression de 45° pour le test, nous constatons une forte confusion entre les classes BRDM2 et 2S1 ce qui dégrade drastiquement le taux de reconnaissance global. Cela est dû à la grande différence des angles de dépression (de 17° à 45°) entre les images SAR d'apprentissage et de test. Cette différence modifie les propriétés globales des images SAR, en particulier la région d'intérêt, et provoque par conséquent un changement brusque des descripteurs de la même cible à partir des angles de dépression différents.

Nous présentons dans le Tableau 4.6 une comparaison entre le temps d'exécution des différentes méthodes sur différentes versions de la base de données MSTAR. Généralement, les remarques de temps d'exécution présentées dans la sous-section 4.5.2 pour les images ISAR sont globalement du même ordre de grandeur que pour le cas des images SAR de la base de données MSTAR. En outre, la méthode SIFT + MSRC nécessite plus de temps d'exécution que la méthode proposée. Nous observons également que la version SOC nécessite un temps d'exécution élevé en utilisant la méthode de classification MSRC. Cela est dû à la grande taille du dictionnaire qui augmente le temps de la résolution du problème d'optimisation convexe.

4.6 Synthèse

Dans ce chapitre, nous avons proposé une nouvelle approche dédiée à la problématique de reconnaissance de cibles à partir des images radar. Cette dernière intègre l'étape de traitement qui a permis de réduire les points clés SIFT localisés dans l'arrière-plan de l'image radar. Cela a été effectué en utilisant la saillance visuelle. En considérant chaque descripteur de point clé comme tâche, la classification parcimonieuse multitâche a été appliquée pour atteindre la phase de reconnaissance.

La méthode proposée (MSKD+MSRC) a été évaluée en effectuant des comparaisons

TABLE 4.5 – Comparaison entre les matrices de confusion (%) obtenues avec la méthode proposée (MSKD+MSRC) et avec les différentes méthodes en considérant la base de données MSTAR sous les conditions EOC-2 (variation des angles de dépression).

		SIFT + matching (72.26)			MSKD + matching (66.54)			SIFT + MSRC (70.63)		
		2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234
15°	2S1	91.61	8.39	0	64.96	20.07	14.96	69.19	15.86	14.95
	BRDM2	27.37	72.62	0	32.48	50	17.52	12.36	78.16	9.48
	ZSU234	29.56	17.88	52.55	11.31	4.01	84.67	16.70	18.76	64.54
					MSKD + MSRC (méthode proposée) (84.18)					
					2S1	BRDM2	ZSU234			
		15°			2S1	6.93	9.85			
					BRDM2	7.66	91.97			
					ZSU234	12.77	9.85			
		SIFT + matching (61.49)			MSKD + matching (53.50)			SIFT + MSRC (49.42)		
		2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234
30°	2S1	11.81	72.22	15.97	61.81	14.24	23.96	37.23	23.48	39.29
	BRDM2	6.19	83.81	10	39.04	27.14	33.81	22.31	50.46	27.23
	ZSU234	11.08	15.27	73.64	20.44	4.67	74.88	21.80	17.63	60.57
					MSKD + MSRC (méthode proposée) (68.58)					
					2S1	BRDM2	ZSU234			
		30°			2S1	6.25	10.76			
					BRDM2	42.85	33.81			
					ZSU234	5.17	0.49			
		SIFT + matching (48.08)			MSKD + matching (43.82)			SIFT + MSRC (37.34)		
		2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234
45°	2S1	45.21	53.79	0.99	32.34	32.34	35.31	30.19	29.74	40.07
	BRDM2	34.51	59.34	6.15	34.99	32.39	32.62	27.38	36.42	36.20
	ZSU234	95.62	3.28	38	23.22	13.27	63.51	21.42	33.17	45.41
					MSKD + MSRC (méthode proposée) (36.32)					
					2S1	BRDM2	ZSU234			
		45°			2S1	85.48	8.25			
					BRDM2	39.24	35.46			
					ZSU234	23.45	17.77			

avec différentes méthodes. L'évaluation a été effectuée en considérant deux types d'images radar à savoir les images ISAR et les images SAR. Les résultats obtenus en considérant la base de données d'images ISAR sont présentés dans la sous-section 4.5.2. Et ceux obtenus en considérant la deuxième base d'images SAR sont donnés dans la sous-section 4.5.3. Pour le cas des images SAR, différentes versions de la base de données MSTAR ont été testées : SOC, EOC-1 et EOC-2 pour différents angles de dépression. Pour comparer la méthode proposée avec les autres méthodes, nous avons utilisé trois critères d'évaluation à savoir le taux de reconnaissance global, le taux de reconnaissance par classe et le temps d'exécution de la méthode considérée. Notre objectif était de démontrer les performances et la robustesse de la méthode proposée appliquée à deux types d'images. Une synthèse des résultats obtenus avec la méthode proposée et appliquée sur les différentes bases de données est présentée par le Tableau 4.7.

TABLE 4.6 – Temps d’exécution (en secondes) de la méthode proposée (MSKD+MSRC) sur les images SAR en comparaison avec les autres méthodes.

Version MSTAR	Méthodes	SIFT + matching	MSKD + matching	SIFT + MSRC	MSKD + MSRC (méthode proposée)
SOC	Traitement	0	0.08	0	0.08
	Extraction de caractéristiques	0.02	0.009	0.02	0.09
	Reconnaissance	76.87	2.46	933.21	780.34
	Total	76.89	2.54	933.23	780.51
EOC-1	Traitement	0	0.09	0	0.09
	Extraction de caractéristiques	0.01	0.008	0.01	0.008
	Recognition	3.14	0.72	57.69	30.01
	Total	3.15	0.81	57.70	30.10
EOC-2 (15°)	Traitement	0	0.09	0	0.09
	Extraction de caractéristiques	0.03	0.007	0.03	0.007
	Recognition	3.93	1.31	60.56	33.06
	Total	3.96	1.40	60.59	33.15
EOC-2 (30°)	Traitement	0	0.06	0	0.06
	Extraction de caractéristiques	0.01	0.003	0.01	0.003
	Recognition	4.13	1.30	60.07	34.35
	Total	4.14	1.36	60.08	34.41
EOC-2 (45°)	Traitement	0	0.06	0	0.06
	Extraction de caractéristiques	0.01	0.004	0.01	0.004
	Recognition	4.29	1.28	62.86	33.13
	Total	4.30	1.34	62.87	33.19

TABLE 4.7 – Synthèse des résultats obtenus en utilisant la méthode proposée (MSKD+MSRC) dans le cas des images SAR et ISAR.

	Images ISAR	Images SAR				
		SOC	EOC-1	EOC-2 (15°)	EOC-2 (30°)	EOC-2 (45°)
Taux de reconnaissance (%)	93.65	80.35	84.54	84.18	68.58	36.32
Temps d’exécution (s)	180.42	780.51	30.10	33.15	34.41	33.19

En ce qui concerne l’étape dédiée à la caractérisation de l’image radar, les résultats d’évaluation ont montré que la stratégie adoptée dans le présent travail contribue à l’augmentation du taux de reconnaissance et accélère significativement la tâche de reconnaissance. Ces deux améliorations sont dues à l’étape de traitement qui permet de bien localiser la région d’intérêt par l’intermédiaire d’un modèle de saillance visuelle. Par conséquent, le calcul de points clés après l’étape de traitement est beaucoup plus rapide que le calcul de tous les points clés de l’image radar. De plus, les points clés sont concentrés dans la région saillante ce qui améliore l’aspect discriminatif du descripteur.

Pour la phase de reconnaissance, malgré que la méthode MSRC est plus lente que la méthode du matching, elle contribue à l’augmentation du taux de reconnaissance. D’autre part, le nombre de tâches utilisé dans la méthode MSRC égale exactement au nombre de points clés. De cela, MSKD réduit le nombre de tâches et accélère par conséquent la tâche de reconnaissance. Nous pouvons conclure que la méthode proposée présente un compro-

mis entre un taux de reconnaissance significatif et un temps d'exécution intéressant.

En comparant les deux types d'images radar, le taux de reconnaissance le plus élevé est obtenu pour les images ISAR (acquises dans un environnement contrôlé). Cela est dû au bruit fortement présent dans le cas des images SAR. Nous constatons aussi que la méthode proposée ne donne pas de résultats satisfaisants pour des angles de dépression élevés (version EOC-2 de la base données MSTAR). Généralement, la différence des angles de dépression a plus d'influence sur le taux de reconnaissance que la différence au niveau des configurations adoptées. Cela est en cohérence avec les résultats présentés dans la littérature pour différentes méthodes [Yu *et al.*, 2018, Chang et You, 2018].

La méthode proposée constitue une contribution dans la problématique de reconnaissance de cibles à partir des images radar. Elle est basée sur l'utilisation d'un dictionnaire générique et fixe pour reconnaître chaque vecteur de test. Cela offre une capacité d'adaptation très limitée. Pour remédier à cela, nous proposons dans le chapitre 5 suivant une nouvelle approche qui construit pour chaque vecteur de test un dictionnaire bien adapté. Cela a été effectué en utilisant des mesures de similarité entre le vecteur de test et tous les atomes du dictionnaire. Cette tâche requiert l'utilisation d'un dictionnaire possédant un nombre réduit d'atomes pour ne pas alourdir le temps d'exécution du processus d'aide à la reconnaissance de cibles. Dans cette optique, au lieu d'utiliser plusieurs atomes pour représenter une image radar, nous utilisons un atome par image radar.

Sommaire

5.1	Introduction	68
5.2	Schéma global de l'approche proposée	68
5.3	Construction du dictionnaire statistique univarié et pondéré	69
5.3.1	Décomposition en ondelettes complexes	70
5.3.2	Modélisation statistique univariée des lois marginales	73
5.3.3	Calcul des poids par mesure de similarité entre les statistiques marginales	77
5.4	Construction du dictionnaire statistique multivarié et pondéré	81
5.4.1	Dépendance entre les coefficients d'ondelettes complexes	82
5.4.2	Modélisation statistique multivariée des lois jointes	83
5.4.3	Calcul des poids par mesure de similarité entre les statistiques jointes	87
5.5	Reconnaissance via la classification parcimonieuse	91
5.6	Application et résultats	91
5.6.1	Présentation de la démarche d'application et d'évaluation	91
5.6.2	Résultats de reconnaissance en considérant les images ISAR	93
5.6.3	Résultats de reconnaissance en considérant les images SAR	95
5.7	Synthèse	99

5.1 Introduction

L'approximation parcimonieuse d'un signal est réalisée en exploitant que quelques atomes constituant le dictionnaire (Cf. chapitre 3). La sélection de ces atomes peut être établie en leur affectant des poids (ou des pondérations) afin de caractériser une importance allouée. Dans le cas idéal, les poids des atomes qui n'appartiennent pas à la vraie classe de l'entrée (images de la base de test) doivent être nuls. Par conséquent, le dictionnaire ne va être composé que par les atomes de la vraie classe du vecteur de test à reconnaître. Cette classification parcimonieuse est dite pondérée (en anglais, WSRC : *Weighted Sparse Representation based Classification*). Elle a été proposée par [Lu *et al.*, 2013] puis améliorée par la suite dans le travail de [Fan *et al.*, 2015]. Dans ces deux travaux, les poids sont calculés en utilisant des mesures de similarité. Ainsi, en plus de la linéarité du classifieur parcimonieux, l'aspect de la localité est aussi ajouté. Ce classifieur a montré ses preuves dans la problématique de reconnaissance de visages en améliorant les performances du SRC. Néanmoins, la mesure de similarité utilisée dans ces travaux ne prend pas en considération la nature des descripteurs du dictionnaire (des atomes) et du vecteur de test. Pour remédier à cette limite, nous proposons dans le présent chapitre deux dictionnaires statistiques ainsi que deux mesures de similarités bien adaptées à la nature des atomes et des données de test. Pour valider cette proposition, les deux bases d'images ISAR et SAR (MSTAR) sont utilisées.

Nous présentons au début de ce chapitre une vue d'ensemble des éléments constituant le schéma global de l'approche proposée. Ensuite, les deux étapes suivantes seront détaillées. Pour la première étape, deux cas de figures sont à distinguer : l'approche univariée et l'approche multivariée. Leurs principes ainsi que leurs différences sont aussi présentés et discutés. En fin de ce chapitre, nous présentons les résultats obtenus en utilisant les deux bases d'images radar retenues pour le travail réalisé et présenté dans ce mémoire.

5.2 Schéma global de l'approche proposée

Nous illustrons dans la Figure 5.1 le schéma global du processus proposé pour l'aide à la reconnaissance de cibles radar à partir des images radar. Il est composé de deux étapes séquentielles : la construction d'un dictionnaire statistique pondéré et la reconnaissance en utilisant la classification parcimonieuse. Ces deux étapes constituent la méthode WSRC.

Dans la première étape, nous calculons les descripteurs des images radar d'apprentissage en adoptant une approche statistique dans le domaine des ondelettes. Ces descripteurs forment ainsi un dictionnaire statistique. Ce dictionnaire est considéré comme étant univarié quand nous adoptons une modélisation statistique univariée (Cf. la section 5.3). Sinon, il est dit multivarié si nous utilisons une modélisation statistique multivariée (Cf. la section 5.4). Pour une image de test à classer, nous calculons son descripteur en utilisant la même approche adoptée pour l'apprentissage. Nous calculons ensuite sa similarité avec

tous les descripteurs de la base d'apprentissage. Cette similarité correspond aux poids de chaque descripteur d'apprentissage à mieux représenter un descripteur de test. Finalement, chaque descripteur d'apprentissage est multiplié par son poids pour générer un dictionnaire statistique pondéré.

Dans la deuxième étape, en utilisant ce dictionnaire pondéré, un problème de minimisation convexe de type ℓ_1 est résolu pour obtenir un vecteur parcimonieux. Finalement, la classe du vecteur de test est celle qui possède l'erreur de reconstruction (résidu) minimale avec le vecteur parcimonieux obtenu.

Les différentes étapes de l'approche proposée sont illustrées par la Figure 5.1 et elles sont détaillées dans les sections 5.3, 5.4 et 5.5.




FIGURE 5.1 – Schéma global de la deuxième approche proposée et appliquée : WSRC-KLD.

5.3 Construction du dictionnaire statistique univarié et pondéré

La Figure 5.2 illustre le schéma adopté pour extraire le vecteur caractéristique d'une image radar via sa modélisation statistique univariée dans le domaine des ondelettes. Chaque brique de ce schéma est détaillée dans ce qui suit.




FIGURE 5.2 – Extraction des caractéristiques d'une image radar en utilisant une modélisation univariée dans le domaine des ondelettes complexes.

5.3.1 Décomposition en ondelettes complexes

La première étape dédiée à l'extraction de caractéristiques retenue dans cette approche concerne la transformation des images (ISAR ou SAR) dans le domaine des ondelettes complexes pour obtenir des présentations multi-échelles (multi-niveaux) et multi-orientations des images. Pour effectuer cette tâche, nous avons eu recours à la méthode des ondelettes complexes à arbres duaux (en anglais, DT-CWT : *Dual Tree Complex Wavelet Transform*) [Kingsbury, 1998, Kingsbury, 1999]. Cette décomposition est largement utilisée dans plusieurs applications de traitement d'images à l'instar de la classification [Celik et Tjahjadi, 2009], la recherche d'images par le contenu [Kwitt et Uhl, 2010], le débruitage [Hill *et al.*, 2014] ou la segmentation [Lo *et al.*, 2011]. Elle est aussi adoptée dans certaines applications de la télédétection [Celik et Ma, 2010, Iqbal *et al.*, 2013, Lewis *et al.*, 2007, Ranjani et Thiruvengadam, 2010, Kennel *et al.*, 2017]. La méthode DT-CWT est une amélioration de la transformée en ondelettes discrètes (en anglais, DWT : *Discrete Wavelet Transform*). En particulier, la DT-CWT surmonte deux faiblesses de la DWT : la non-invariance par translation et le manque de sélectivité directionnelle. La non-invariance par translation signifie que les coefficients obtenus par la DWT ne seront pas les mêmes si on décale l'image originale. La DWT fournit que trois orientations par échelle de décomposition (verticale, horizontale et diagonale) ce qui engendre une faiblesse au niveau de la sélectivité directionnelle. Pour remédier à ces lacunes, la DT-CWT grâce à l'utilisation de deux arbres DWT différents a été développée et proposée. En effet, elle produit pour chaque échelle six sous-bandes complexes correspondants à six orientations ($-75^\circ, -45^\circ, -15^\circ, +15^\circ, +45^\circ, +75^\circ$). Et nous soulignons que chaque sous-bande est invariante à la translation.

Le principe de la DT-CWT est illustré par la Figure 5.3. Les deux arbres forment




FIGURE 5.3 – Principe de la DT-CWT.

la base de cette méthode. Pour chaque arbre, différents filtres passe-haut ($h1$ et $g1$) et passe-bas ($h0$ et $g0$) sont utilisés. Nous soulignons que cette méthode permet de générer des coefficients complexes qui s'écrivent chacun sous la forme : $z = a + ib$, avec a est la partie réelle et b est la partie imaginaire. Le premier arbre produit des coefficients de la partie réelle. Tandis que le deuxième arbre génère les coefficients imaginaires. À partir de ces coefficients complexes, plusieurs informations peuvent être extraites :

- L'amplitude : $amp = |z| = |a + ib| = \sqrt{a^2 + b^2}$
- La phase : $\phi_{ph} = \arctan\left(\frac{Im(z)}{Re(z)}\right) = \arctan\left(\frac{a}{b}\right)$
- La phase relative : $\phi_{rel} = \phi_{ph_1} - \phi_{ph_2}$, avec ϕ_{ph_1} et ϕ_{ph_2} représentent la phase de deux sous-bandes complexes adjacents.

Dans le présent travail, nous nous intéressons à l'information de l'amplitude extraite des sous-bandes complexes. Nous illustrons dans la Figure 5.4 et la Figure 5.5 un exemple représentant des amplitudes des sous-bandes complexes produites par la DT-CWT sur des images ISAR et SAR respectivement. Cela est appliquée pour le cas des images ISAR (Cf. Figure 5.4) et pour le cas des images SAR (Cf. Figure 5.5). Nous rappelons que le vecteur caractéristique des images radar sera composé des paramètres statistiques estimés à partir les amplitudes des sous-bandes extraites. Nous considérons donc les amplitudes extraites comme étant un ensemble des variables aléatoires univariées "RVU" :

$$RVU = (RVU^j)_{1 \leq j \leq 6J} \quad (5.1)$$

avec j est l'indice de la sous-bande complexe et J est le niveau de décomposition. L'étude statistique de "RVU" va nous ramener à choisir le type des modèles statistiques aptes à bien la décrire.




FIGURE 5.4 – Illustration d'une image ISAR (a) avec les amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).




FIGURE 5.5 – Illustration d'une image SAR (a) avec les amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).

Nous présentons dans la Figure 5.6 et la Figure 5.7 les histogrammes des amplitudes des sous-bandes illustrées par la Figure 5.4 et la Figure 5.5. À partir de ces histogrammes, nous constatons, d'une part, un phénomène de leptokurticité qui se manifeste par une queue lourde. Cela exige l'utilisation des lois non-Gaussiennes. D'autre part, les distributions des variables aléatoires sont asymétriques et elles sont décalées vers la gauche tout en ayant des queues étalées vers la droite. Afin de vérifier ce comportement statistique pour toutes les sous-bandes des deux bases de données d'images radar, nous utilisons le coefficient d'asymétrie (en anglais, *skewness*) [Von Hippel, 2005]. Ce coefficient qui représente le cumulants d'ordre trois est calculé comme suit :


$$\text{skewness} = \frac{\frac{\sum_{i=1}^L (va_i - \overline{va})^3}{L}}{\frac{\sum_{i=1}^L (va_i - \overline{va})^2}{L}} \quad (5.2)$$

avec $\overline{va}$ est la moyenne et L est la longueur de la variable aléatoire va .


Ainsi, la forme de l'allure statistique d'une variable aléatoire est déterminée selon différents cas :

- Si le coefficient d'asymétrie est > 0 , alors la distribution est asymétrique et elle est décalée à gauche de la moyenne avec une queue de distribution étalée vers la droite.
- Si le coefficient d'asymétrie est < 0 , alors la distribution est asymétrique et elle est décalée à droite de la moyenne avec une queue de distribution étalée vers la gauche.

- Si le coefficient d'asymétrie est $= 0$, alors la distribution est symétrique.



(a)



(b)

FIGURE 5.6 – Illustration d'une image ISAR (a) avec les histogrammes des amplitudes de ses six sous-bandes complexes (DT-CWT) dans l'échelle 1 (b).

Les valeurs des coefficients d'asymétrie de l'amplitude des sous-bandes complexes des images SAR et ISAR sont données dans le Tableau 5.1. Ces résultats confirment les conclusions déduites à partir des histogrammes. Par conséquent, le modèle statistique à choisir doit avoir l'aptitude de modéliser des variables aléatoires positives et asymétriques. La famille des distributions de Weibull et Gamma reste un choix judicieux pour décrire le comportement statistique de telles variables aléatoires, ce choix est démontré dans les travaux de [Kwitt et Uhl, 2010, Kwitt, 2010]. Une description de ces deux lois sera présentée dans la sous-section 5.3.2.

5.3.2 Modélisation statistique univariée des lois marginales

Pour décrire les amplitudes des coefficients issues de la DT-CWT, la distribution de Rayleigh a été initialement utilisée. Elle est caractérisée par un seul paramètre de forme. Cette distribution nécessite que la partie réelle et la partie imaginaire des coefficients aient




FIGURE 5.7 – Illustration d’une image SAR (a) avec les histogrammes des amplitudes de ses six sous-bandes complexes (DT-CWT) dans l’échelle 1 (b).

Base de données	ISAR	SAR		
		SOC	EOC-1	EOC-2
Minimum des coefficients d’asymétrie	1.72	0.23	0.29	0.28
Maximum des coefficients d’asymétrie	38.02	16.04	12.06	15.35
Moyenne des coefficients d’asymétrie	9.82	2.09	2.26	1.98

TABLE 5.1 – Coefficients d’asymétrie des images SAR et ISAR.

une allure Gaussienne, mais qui n’est pas malheureusement toujours le cas. Afin de palier à ces limitations, les auteurs dans [Kwitt et Uhl, 2010, Kwitt et Uhl, 2008] ont privilégié l’utilisation des distributions de Weibull et Gamma. Motivés par leurs performances dans la recherche d’images par le contenu, nous adoptons ces deux distributions dans le cadre de l’application traitée dans ce travail.

5.3.2.1 Distribution Gamma

Soit x' une variable aléatoire positive ($x' \in \mathbb{R}^+$). Si x' suit la loi Gamma, sa fonction de densité de probabilité (en anglais, PDF : *Probability Density Function*) est donnée par [Krishnamoorthy, 2006] :

$$f(x'; \theta) = \frac{a^{-b} x'^{b-1}}{\Gamma(b)} \exp\left(-\frac{x'}{a}\right) \quad (5.3)$$

avec

- $\theta = (b, a)$: les deux paramètres Gamma qui influencent sa PDF
- $b > 0$: le paramètre de forme
- $a > 0$: le paramètre d'échelle
- $\Gamma(z) = \int_0^{\infty} t^{z-1} e^{-t} dt$: la fonction Gamma

La Figure 5.8 illustre l'influence des paramètres b et a sur l'allure de la PDF de la distribution Gamma. Nous constatons qu'en agrandissant le paramètre de forme b , la décroissance de la distribution devient autant lourde. D'autre part, le paramètre d'échelle a régit sur l'étalement de la courbe, plus a est grand plus la distribution est étalée. La méthode




FIGURE 5.8 – Représentation de la densité de probabilité de la loi Gamma, (a) Influence du paramètre de forme b sur la densité de probabilité pour $a = 1$, (b) Influence du paramètre d'échelle a sur la densité de probabilité pour $b = 3$.

de maximum de vraisemblance (en anglais, ML : *Maximum Likelihood*) est retenue pour estimer les deux paramètres statistiques de la loi Gamma [Kwitt et Uhl, 2010]. Plus de détails sur cette méthode sont donnés dans la sous-section A.1.1 de l'annexe A.

5.3.2.2 Distribution de Weibull

La loi de Weibull est gouvernée aussi par un paramètre de forme et un paramètre d'échelle. Sa PDF pour une variable aléatoire $x' \in \mathbb{R}^+$ est définie comme suit :

$$f(x'; \theta) = \frac{\tau}{\mu} \left(\frac{x'}{\mu} \right)^{\tau-1} \exp \left(- \left(\frac{x'}{\mu} \right)^{\tau} \right) \quad (5.4)$$

avec

- $\theta = (\tau, \mu)$: les deux paramètres de Weibull qui influencent sa PDF
- $\tau > 0$: le paramètre de forme
- $\mu > 0$: le paramètre d'échelle

La Figure 5.9 illustre l'influence des paramètres de forme τ et d'échelle μ sur l'allure de la PDF de la distribution de Weibull. Cette figure montre que plus τ est petite, plus la leptokurticité est importante. Concernant le paramètre d'échelle μ , l'étalement de la courbe devient de plus en plus important pour des grandes valeurs de μ .




FIGURE 5.9 – Représentation de la densité de probabilité de la loi de Weibull, (a) Influence du paramètre de forme τ sur la densité de probabilité pour $\mu = 1$, (b) Influence du paramètre d'échelle μ sur la densité de probabilité pour $\tau = 3$.

Pour estimer les deux paramètres statistiques de la loi de Weibull, la méthode du ML est utilisée. Cette dernière est décrite dans la sous-section A.1.2 de l'annexe A.

5.3.2.3 Qualité de l'ajustement des statistiques marginales

Nous étudions dans les Figures 5.10 et 5.11 la qualité d'ajustement des amplitudes des coefficients DT-CWT correspondantes à une image SAR et ISAR radar par les deux distributions Gamma ou Weibull. Ainsi, nous comparons les PDF estimées par les deux lois avec les PDF empiriques (histogrammes). Nous constatons que les PDF estimées sont

très proches des PDF empiriques, ce qui montre un ajustement des modèles statistiques adoptés avec la variable aléatoire considérée.

L'ajustement de la PDF estimée à la PDF empirique pour une seule image radar de toute la base de données n'est pas suffisant pour décider à propos de la qualité de l'ajustement d'un modèle statistique avec l'ensemble des données d'entrée. C'est dans cette optique que nous avons réalisé un test quantitatif des deux modèles statistiques sur toutes les images des deux bases de données afin de confirmer cette inspection visuelle. Ce test a été effectué en utilisant le test de Kolmogorov-Smirnov (KS) [Massey Jr, 1951]. Par définition, le test KS calcule la différence entre les fonctions de répartition théoriques et estimées. Une petite valeur de KS indique une grande qualité de l'ajustement des données avec la distribution testée. Nous présentons dans le Tableau 5.2 la valeur moyenne du test de KS en utilisant les lois de Weibull et Gamma. Nous obtenons pour les deux bases de données d'images radar des petites valeurs du KS pour les deux distributions testées. Cela montre que ces deux distributions présentent des ajustements satisfaisants et justifient leurs utilisations pour décrire l'allure statistique des amplitudes des coefficients DT-CWT des images radar. En outre, nous soulignons une supériorité de la loi Gamma par rapport à la loi de Weibull.

Base de données	ISAR		SAR					
			SOC		EOC-1		EOC-2	
Modèles statistiques univariés	Weibull	Gamma	Weibull	Gamma	Weibull	Gamma	Weibull	Gamma
KS	0.1384	0.1325	0.1643	0.1592	0.0894	0.0723	0.0364	0.0337

TABLE 5.2 – Pourcentage de rejet de l'hypothèse nulle en utilisant le test de Kolmogorov-Smirnov appliqué sur les amplitudes des coefficients DT-CWT des images radar pour deux modèles statistiques univariés (Weibull et Gamma).

Une fois les vecteurs caractéristiques de toutes les images sont calculés, nous exploitons la mesure de similarité entre les images de la base de test et la base d'apprentissage pour affecter des poids aux atomes du dictionnaire (Cf. Figure 5.1).

5.3.3 Calcul des poids par mesure de similarité entre les statistiques marginales

Nous notons $V_p = (FV^{\text{train}})$ pour faire référence à un vecteur caractéristique de l'image p de la base d'apprentissage avec $1 \leq p \leq n$ et n le nombre d'images dans la base d'apprentissage. $FV^{\text{train}} = (\theta^{\text{train},j})_{1 \leq j \leq 6J}$ sont les paramètres statistiques (Gamma ou Weibull) estimés des amplitudes des coefficients de la DT-CWT pour chaque $RVU^{\text{train}} = (RVU^{\text{train},j})_{1 \leq j \leq 6J}$. Finalement, le dictionnaire statistique univarié $A \in \mathbb{R}^{m \times n}$ est obtenu




FIGURE 5.10 – Comparaison entre la PDF empirique et la PDF estimée des lois Gamma et Weibull pour l’amplitude des sous-bandes complexes (b) d’une image ISAR (a).

par la concaténation des descripteurs $V_p \in \mathbb{R}^{m \times 1}$ (atomes) de la base d’apprentissage :

$$A = \begin{matrix} & V_1 & \dots & V_n \\ \begin{matrix} 1 \\ \vdots \\ m \end{matrix} & \begin{bmatrix} \dots & \dots & \vdots \\ \vdots & \ddots & \vdots \\ \dots & \dots & \vdots \end{bmatrix} \end{matrix} \quad (5.5)$$

avec n le nombre des images d’apprentissage et m correspond à la dimension du descripteur qui est égale à $nbp \times 6J$, avec nbp est le nombre de paramètres statistiques estimés pour chaque sous-bande (égale à 2 dans le cas des lois Gamma ou Weibull).




FIGURE 5.11 – Comparaison entre la PDF empirique et la PDF estimée des lois Gamma et Weibull pour l'amplitude des sous-bandes complexes (b) d'une image SAR (a).

Dans le présent travail, le descripteur de l'image de test est calculé de la même manière que celui des images d'apprentissages. Nous utilisons la notation $y = (FV^{\text{test}}) \in \mathbb{R}^{m \times 1}$ pour faire référence au descripteur de la base de test, avec $FV^{\text{test}} = (\theta^{\text{test},j})_{1 \leq j \leq 6J}$ sont les paramètres statistiques estimés à partir des amplitudes des coefficients de la DT-CWT pour chaque $RVU^{\text{test}} = (RVU^{\text{test},j})_{1 \leq j \leq 6J}$. Pour mesurer l'importance des descripteurs d'apprentissage selon le vecteur de test à classifier, nous avons transformé le dictionnaire statistique A en un dictionnaire pondéré A' . Les cibles radar de la base d'apprentissage qui sont similaires à une cible radar de test doivent avoir des poids plus grands que celles non similaires. En effet, nous avons attribué un poids à chaque atome (une image) dans le dictionnaire A par l'intermédiaire de l'information de similarité. Nous adoptons dans la méthode proposée un dictionnaire statistique. Donc, il est judicieux de recourir à des mesures de similarités entre les fonctions de densité de probabilité des distributions utilisées.

Dans cette optique, nous avons retenu une distance qui intègre la KLD (Kullbak-Leibler Divergence) [Joyce, 2011]. Cette mesure, issue de la théorie de l'information, permet de calculer la divergence entre deux distributions de probabilité f_1 et f_2 . Sa forme générale est donnée par :

$$KLD(f_1||f_2) = \int_{+\infty}^{-\infty} f_1(x') \ln \frac{f_1(x')}{f_2(x')} dx' \quad (5.6)$$

À partir de l'équation (5.6), les auteurs dans [Kwitt et Uhl, 2008] ont proposé une formule analytique de la KLD entre deux distributions Gamma ou Weibull :

- La formule de la KLD entre deux distributions Gamma $f_1(x'; b_1, a_1)$ et $f_2(x'; b_2, a_2)$ est donnée par :

$$\begin{aligned} \text{KLD}_{Gamma}(f_1(x'; b_1, a_1)||f_2(x'; b_2, a_2)) &= \Phi(b_1)(b_1 - b_2) - b_1 + \log \left(\frac{\Gamma(b_2)}{\Gamma(b_1)} \right) \\ &+ b_2 \log \left(\frac{a_1}{a_2} \right) + \frac{b_1 a_1}{a_2} \end{aligned} \quad (5.7)$$

avec $\Phi(x') = \Gamma'(x')/\Gamma(x')$ est la fonction digamma.

- La KLD entre deux distributions de Weibull $f_1(x'; \tau_1, \mu_1)$ et $f_2(x'; \tau_2, \mu_2)$ peut être calculée par :

$$\begin{aligned} \text{KLD}_{Weibull}(f_1(x'; \tau_1, \mu_1)||f_2(x'; \tau_2, \mu_2)) &= \Gamma \left(\frac{\tau_2}{\tau_1} + 1 \right) \left(\frac{\mu_1}{\mu_2} \right)^{\tau_2} + \log(\mu_1^{-\tau_1} \tau_1) - \log(\mu_2^{-\tau_2} \tau_2) \\ &+ \log(\mu_1) \tau_1 \log(\mu_1) \tau_2 + \frac{\gamma \tau_2}{\tau_1} - \gamma - 1 \end{aligned} \quad (5.8)$$

avec γ est le négative de la fonction digamma $\Phi(x') = \Gamma'(x')/\Gamma(x')$.

Le calcul de la KLD entre deux images représentées par leurs descripteurs y et V_p respectivement revient à mesurer la KLD entre leurs paramètres statistiques dans le domaine des ondelettes complexes :


$$d_{KLD}(y, V_p) = \sum_{j=1}^{6J} KLD(f_1(\text{RVU}^{\text{test},j}; \theta^{\text{test},j}) || f_2(\text{RVU}^{\text{train},j}; \theta^{\text{train},j})) \quad (5.9)$$

Une petite valeur de la KLD (d_{KLD}) signifie une grande similarité entre l'image représentée par y et l'image représentée par V_p . Par conséquent, le poids W_p^y attribué au vecteur V_p à représenter y doit avoir une grande valeur. Cela peut être obtenu en s'appuyant sur le comportement de la fonction $\exp(-d_{KLD})$ illustrée par la Figure 5.12. Cette fonction est strictement décroissante dans l'intervalle $[0, +\infty]$.

Finalement, la distance proposée "Dist" entre un descripteur de test y et un descripteur d'apprentissage V_p est donnée comme suit :

$$\text{Dist}(y, V_p) = \exp(-d_{KLD}(y, V_p)) = W_p^y \quad (5.10)$$

D'après la Figure 5.12, les distances obtenues en utilisant l'équation (5.10) peuvent être

FIGURE 5.12 – Courbe représentative de la fonction $\exp(-d_{KLD})$.

directement utilisées comme des poids puisque leurs valeurs varient entre 0 et 1. Par exemple, la distance entre une image et soi-même est égale à 0, donc son poids est égal à $\exp(0) = 1$.

Après le calcul du poids de chaque vecteur d'apprentissage par rapport au vecteur de test à classifier, le dictionnaire statistique univarié et pondéré $A' \in \mathbb{R}^{m \times n}$ est obtenu en utilisant la représentation suivante :

$$A' = \begin{matrix} & W_1^y V_1 & \dots & W_n^y V_n \\ \begin{matrix} 1 \\ \vdots \\ m \end{matrix} & \left[\begin{array}{ccc} & \dots & \\ \vdots & \ddots & \vdots \\ & \dots & \end{array} \right] \end{matrix} \quad (5.11)$$

En suivant cette stratégie, le dictionnaire générique A est remplacé par un dictionnaire pondéré A' spécifique à chaque vecteur de test (image de la base de test) à classifier. Ce dictionnaire pondéré a la particularité d'intégrer les informations de linéarité et de localité (similarité) entre les vecteurs de test et les vecteurs d'apprentissage.

5.4 Construction du dictionnaire statistique multivarié et pondéré

Dans la section 5.3, nous avons supposé que les amplitudes des coefficients d'ondelettes complexes sont indépendantes. Nous nous intéressons tout au long de cette section à l'étude de leurs dépendances tout en mettant en évidence leurs modélisations multivariées ou plus précisément bivariées. Ce processus de caractérisation des images radar est schématisé par la Figure 5.13.




FIGURE 5.13 – Extraction des caractéristiques d'une image radar en utilisant une modélisation bivariée dans le domaine des ondelettes complexes.

5.4.1 Dépendance entre les coefficients d'ondelettes complexes

Pour modéliser conjointement les coefficients d'ondelettes des images à niveaux de gris, trois types de dépendance peuvent être considérés :

- **La dépendance intra-bande** : elle se base sur la considération de la relation entre un coefficient avec ses coefficients voisins sur la même sous-bande. Elle correspond à une dépendance spatiale entre les coefficients.
- **La dépendance inter-orientation** : elle prend en compte la relation entre un coefficient et son homologue (appelé cousin) d'une autre orientation dans la même échelle.
- **La dépendance inter-échelles** : elle associe un coefficient avec un autre coefficient (appelé fils) localisé à la même position spatiale et la même orientation à l'échelle au-dessous. Cette dépendance exige l'utilisation d'un niveau de décomposition des ondelettes supérieur ou égal à deux.

Afin de montrer l'existence et le degré de la dépendance entre les amplitudes des coefficients complexes des images ISAR et SAR, nous avons fait appel au test graphique Chi-plot [Fisher et Switzer, 1985]. Ce dernier se base sur le calcul d'un couple (χ_i, λ_i) pour toute réalisation $(sb1_i, sb2_i)$ d'un vecteur aléatoire bidimensionnel $(SB1, SB2)$. Pour obtenir ce couple, nous calculons d'abord :

$$\begin{aligned}
 H_i &= \sum_{j \neq i} \frac{P(sb1_j \leq sb1_i, sb2_j \leq sb2_i)}{M-1} \\
 F_i &= \sum_{j \neq i} \frac{P(sb1_j \leq sb1_i)}{M-1} \\
 G_i &= \sum_{j \neq i} \frac{P(sb2_j \leq sb2_i)}{M-1} \\
 S_i &= \text{sign}((F_i - 0.5)(G_i - 0.5))
 \end{aligned} \tag{5.12}$$

où P est une fonction caractéristique qui est défini par : $P(A) = 1$ si A est vrai, sinon $P(A) = 0$.

Ensuite, nous calculons :

$$\begin{aligned}\chi_i &= \frac{H_i - F_i G_i}{\sqrt{F_i(1 - F_i)G_i(1 - G_i)}} \\ \lambda_i &= 4S_i \max((F_i - 0.5)^2, (G_i - 0.5)^2)\end{aligned}\tag{5.13}$$

À partir de ce couple, un nuage de points est considéré. Plus ce nuage est loin d'une bande de tolérance, plus les données sont dépendantes. Si la totalité des points est à l'intérieur de la bande de tolérance, nous concluons une indépendance entre $SB1$ et $SB2$ (absence de dépendance). Cette bande de tolérance est définie par les deux lignes horizontales $\chi = -c_p/\sqrt{M}$ et $\chi = c_p/\sqrt{M}$, avec $c_p = 1.54, 1.78$ et 2.18 respectivement pour $p = 0.9, 0.95$ et 0.99 . Les différentes valeurs des c_p ont été proposées par simulation de Monte-Carlo dans [Fisher et Switzer, 2001].

Nous comparons dans la Figure 5.14 les trois types de dépendances en utilisant le test Chi-plot pour une image ISAR et une image SAR. Nous pouvons constater que la dépendance inter-orientation est beaucoup plus importante que les autres types de dépendance. Néanmoins, les dépendances intra-bande et inter-échelle existent aussi puisqu'un nombre considérable de points sont localisés à l'extérieur de la bande de tolérance. Nous nous sommes intéressés essentiellement dans le cadre de la présente thèse à la dépendance inter-orientation. Nous considérons par conséquent une dépendance entre les coefficients de deux orientations différentes. Ces orientations correspondent aux degrés positifs et négatifs d'une même orientation pour la même échelle de décomposition. Ainsi, le vecteur aléatoire bidimensionnel (composé de deux vecteurs aléatoires) pour une orientation (degré) $o \in \{15^\circ, 45^\circ, 75^\circ\}$ d'une échelle J est défini comme suit :

$$\text{RVM}_o^J = [SB_{+o,J}, SB_{-o,J}]\tag{5.14}$$

Par conséquent, le nombre total de vecteurs bidimensionnels générés pour une seule image est égal à $3 \times J$.

Afin de prendre en considération la dépendance du vecteur bidimensionnel (Cf. Équation 5.14), nous avons modélisé sa loi jointe en utilisant des modèles multivariés basés sur la théorie des copules [Sklar, 1959]. Une description de cette dernière est présentée dans la sous-section 5.4.2.

5.4.2 Modélisation statistique multivariée des lois jointes

Dans le contexte de la modélisation multivariée, la copule présente un outil très fort et prometteur pour deux raisons majeures : sa séparation de la structure de dépendance et le comportement de la loi marginale des vecteurs aléatoires ainsi que sa capacité à construire des distributions jointes à partir des distributions marginales. Grâce à ses facteurs, les copules ont été largement utilisées dans plusieurs applications à l'instar de la recherche d'images par contenu [Kwitt, 2010, Lasmar, 2012] ou la classification des images [Voisin *et al.*, 2014] ou la détection des changements dans les images satellitaires [Mercier *et al.*, 2008].




FIGURE 5.14 – Test Chi-plots de trois types dépendances pour une image ISAR (a) et une image SAR (b). La première colonne correspond à la dépendance intra-bande. La deuxième colonne montre la dépendance inter-orientation. La dernière colonne illustre la dépendance inter-échelle.

5.4.2.1 La notion de copule

Soit $U = (u_1, \dots, u_d)$ un vecteur aléatoire multidimensionnel de dimension d , on appelle copule C de dimension d toute fonction de répartition multivariée définie sur $[0, 1]^d$ et dont les lois marginales sont uniformément distribuées sur $[0, 1]$. C doit satisfaire les propriétés suivantes :

1. $\forall u \in [0, 1]^d$,
 - si $\exists u_i = 0$ alors $C(u) = 0$
 - $C(1, \dots, 1, u_i, 1, \dots, 1) = u_i$
2. C est croissante pour chaque composant u_i

Le succès des copules tire profit du théorème de Sklar [Sklar, 1959]. Ce dernier montre que la construction d'une loi jointe se fonde sur la structure de dépendance et des lois marginales. Ce théorème reste fondamental dans la théorie des copules. Si F et F_i sont respectivement les fonctions de répartitions jointes et marginales du vecteur U alors il existe une copule C telle que :

$$F(u_1, \dots, u_d) = C(F_1(u_1), \dots, F_d(u_d)) \quad (5.15)$$

L'équation (5.15) montre que si on possède une distribution multivariée ainsi qu'un ensemble de distributions univariées correspondantes, alors il existe une copule C les re-

liant. Inversement, si on définit une copule C et des fonctions de répartition marginale F_i , alors la fonction de répartition jointe de ces fonctions marginales est définie par $C(F_1(u_1), \dots, F_d(u_d))$.

De plus, si les F_i sont continues, alors la copule C est unique et elle est obtenue par la formule :

$$C(e_1, \dots, e_d) = F(F_1^{-1}(e_1), \dots, F_d^{-1}(e_d)) \quad (5.16)$$

tel que $e_i = F_i(u_i)$.

Si la copule C est continue et différentiable alors sa densité de copule c est :

$$c(b_1, \dots, b_d) = \frac{\partial^d C(b_1, \dots, b_d)}{\partial e_1 \dots \partial e_d} \quad (5.17)$$

De cela découle la PDF jointe de la copule :

$$f(u_1, \dots, u_d) = c(F_1(u_1), \dots, F_d(u_d)) \prod_{i=1}^d f_i(u_i) \quad (5.18)$$

avec $f_{i \in \{1, \dots, d\}}$ sont les densités marginales. L'équation (5.18) montre que pour construire un modèle multivarié basé sur les copules, il faut déterminer la fonction de la copule C (cela revient à déterminer sa densité c) et la PDF de la loi marginale f (la fonction de répartition F_i émanera de la PDF f). Cette liberté dans le paramétrage offre une grande flexibilité pour proposer autant de lois jointes. Autrement dit, avec le même type de copule C , nous pouvons construire différents modèles multivariés en variant juste la PDF f de la loi marginale.

Plusieurs familles de copules pour définir C sont proposées dans la littérature. Parmi elles, nous citons :

Copules Archimédiennes

Elles s'écrivent sous la forme suivante :

$$C(e_1, \dots, e_d) = \eta^{-1}(\eta(e_1) + \dots + \eta(e_d)) \quad (5.19)$$

avec η est la fonction génératrice de la copule. Elle doit être strictement croissante de $[0, 1]$ vers $[0, +\infty[$ vérifiant $\eta(1) = 0$. À partir de cette fonction, plusieurs copules peuvent être déterminées, nous avons notamment :

- La copule de Clayton qui utilise la fonction génératrice $\eta(xx) = \frac{x^{-pp}-1}{pp}$, $pp \geq -1$
- La copule de Gumbel qui utilise la fonction génératrice $\eta(xx) = (-\ln(xx))^{pp}$, $pp \geq -1$
- La copule de Frank qui utilise la fonction génératrice $\eta(xx) = -\ln \frac{e^{-pp \times xx} - 1}{e^{-\alpha} - 1}$, $pp \neq 0$

Copules elliptiques

La densité des copules elliptiques est obtenue à partir des lois multivariées. Nous présentons deux fameux types de cette famille de copule.

— La copule Gaussienne (en anglais, GC : *Gaussian Copula*) dont la densité s'écrit :

$$c(e_1, \dots, e_d) = \frac{1}{|\Sigma|^{1/2}} \exp \frac{-\vec{h}^t (\Sigma^{-1} - I_d) \vec{h}}{2} \quad (5.20)$$

où Σ représente la matrice de covariance à diagonale unité et de taille $d \times d$, I_d est la matrice d'identité, $\vec{h}^t = (yy_1, \dots, yy_d)^t$ est le vecteur Gaussien tel que $yy_i = \varpi^{-1}(e_i)$ et ϖ est la fonction de répartition de la distribution normale univariée $N(0, 1)$.

— La copule t-Student dont la densité est donnée par :

$$c(e_1, \dots, e_d) = \frac{\Gamma\left(\frac{\nu+d}{2}\right) [\Gamma\left(\frac{\nu}{2}\right)]^d \left(1 + \frac{\vec{h}^t \Sigma^{-1} \vec{h}}{\nu}\right)^{-\frac{\nu+d}{2}}}{|\Sigma|^{1/2} \Gamma\left(\frac{\nu}{2}\right) \prod_{i=1}^d \left(1 + \frac{y_i^2}{\nu}\right)^{-\frac{\nu+1}{2}}} \quad (5.21)$$

où Γ est la fonction Gamma, $\vec{h}^t = (F_t^{-1}(e_1; \nu), \dots, F_t^{-1}(e_d; \nu))$ avec $F_t^{-1}(e_i; \nu)$ est la fonction de répartition de t-Student ayant le degré de liberté ν .

Les copules elliptiques (Gaussienne et t-Student) sont les plus utilisées dans le cadre de la modélisation des images [Kwitt *et al.*, 2011, Lasmar et Berthoumieu, 2014, Li *et al.*, 2017b, Rami *et al.*, 2014]. Dans le travail de [Kwitt *et al.*, 2011], les auteurs ont noté que les performances de la copule Gaussienne et la copule t-Student sont très proches en terme de performance. Dans ce contexte, nous adoptons la copule Gaussienne pour décrire les dépendances. Cela est dû à sa simplicité pour estimer les paramètres statistiques ainsi que l'existence d'une forme analytique rapide en temps d'exécution de la KLD entre ses PDF [Lasmar et Berthoumieu, 2014].

Quant au choix des lois marginales, nous avons déjà montré dans la sous-section 5.3.2 que les modèles univariés Gamma et Weibull décrivent bien l'allure statistique de la variable aléatoire considérée. Par conséquent, nous avons considéré deux modèles multivariés utilisant la même copule (copule Gaussienne) avec une différence au niveau de la loi marginale. Le premier modèle utilise la distribution Gamma comme loi marginale. Nous notons sa PDF par GC-Gam, elle est définie par :

$$\begin{aligned} f(\vec{x}; p) &= \frac{1}{|\Sigma|^{1/2}} \exp \frac{-\vec{h}^t (\Sigma^{-1} - I) \vec{h}}{2} \times \prod_{i=1}^d f_i(x'_i; b_i, a_i) \\ &= \frac{1}{|\Sigma|^{1/2}} \exp \frac{-\vec{h}^t (\Sigma^{-1} - I) \vec{h}}{2} \times \prod_{i=1}^d \frac{a_i^{-b_i} a_i^{b_i-1}}{\Gamma(b_i)} \exp \left(-\frac{x'_i}{a_i} \right) \end{aligned} \quad (5.22)$$

Le deuxième modèle multivarié utilise la loi de Weibull pour décrire les statistiques marginales. Pour la suite on note sa PDF par GC-Wbl, et elle est définie par :

$$\begin{aligned} f(\vec{x}; p) &= \frac{1}{|\Sigma|^{1/2}} \exp \frac{-\vec{h}^t (\Sigma^{-1} - I) \vec{h}}{2} \times \prod_{i=1}^d f_i(x'_i; \tau_i, \mu_i) \\ &= \frac{1}{|\Sigma|^{1/2}} \exp \frac{-\vec{h}^t (\Sigma^{-1} - I) \vec{h}}{2} \times \prod_{i=1}^d \frac{\tau_i}{\mu_i} \left(\frac{x'_i}{\mu_i} \right)^{\tau_i-1} \exp \left(-\left(\frac{x'_i}{\mu_i} \right)^{\tau_i} \right) \end{aligned} \quad (5.23)$$

De ce fait, les hyperparamètres de loi jointe sont $p = (\{\theta_1, \dots, \theta_d\}; \Sigma)$. Les θ_i sont les paramètres des lois marginales (Gamma ou Weibull) et Σ présente la covariance qui est le paramètre caractérisant la copule. Afin d'estimer ces hyperparamètres, nous utilisons la méthode IFM (*Inference Functions from Margins*) [Joe, 1997]. Une description de cette méthode est donnée dans la section A.2 de l'annexe A.

5.4.2.2 Qualité de l'ajustement des statistiques jointes

Les figures 5.15 et 5.16 illustrent l'ajustement des deux modèles multivariés proposés à la PDF jointe empirique en vues 3D (première ligne) et 2D (deuxième ligne). Nous considérons un couple de sous-bandes d'orientation -45° et $+45^\circ$ dans la première échelle de décomposition pour le cas d'une image ISAR (Cf. Figure 5.15) et d'une image SAR (Cf. Figure 5.16). Plusieurs remarques peuvent être dressées à partir de ces deux figures. Tout d'abord, nous constatons que les deux distributions GC-Gam et GC-Wbl sont très proches de la PDF empirique ce qui montre un bon ajustement des lois jointes considérées. Ensuite, à partir des valeurs des hyperparamètres estimés, nous remarquons que les paramètres des distributions marginales des deux sous-bandes ont des valeurs très proches. Cela est dû à leurs fortes dépendances. La matrice de covariance affirme aussi la structure de dépendance.

Pour quantifier la qualité de l'ajustement des lois jointes pour toutes les images de chaque base de données, nous avons utilisé le test KS. Les valeurs de ce test sont indiquées dans le Tableau 5.3. Pour les deux types d'images, les valeurs de KS obtenues sont inférieures à 1. Cela conforte le choix de l'utilisation des modèles multivariés considérés pour modéliser la dépendance inter-orientation.

Base de données	ISAR		SAR					
			SOC		EOC-1		EOC-2	
Modèles statistiques multivariés	GC-Wbl	GC-Gam	GC-Wbl	GC-Gam	GC-Wbl	GC-Gam	GC-Wbl	GC-Gam
KS	0.4216	0.4215	0.4141	0.4142	0.4179	0.4178	0.4164	0.4163

TABLE 5.3 – Pourcentage de rejet de l'hypothèse nulle en utilisant le test de Kolmogorov-Smirnov appliqué sur les amplitudes des coefficients DT-CWT des images radar pour deux modèles statistiques multivariés (GC-Wbl et GC-Gam).

5.4.3 Calcul des poids par mesure de similarité entre les statistiques jointes

Nous désignons par $V_p = (FV^{\text{train}})$ un vecteur de la base d'apprentissage. Avec $FV^{\text{train}} = (\theta^{\text{train},j}, \Sigma_{SB_{\pm o,t}})_{\substack{1 \leq t \leq 3J \\ 1 \leq j \leq 6J}}$ sont les hyperparamètres statistiques multivariés (GC-Gam ou GC-Wbl) estimés depuis les coefficients de la DT-CWT pour chaque vecteur bidimensionnel $RVM_o^j = [SB_{o,j}, SB_{-o,j}]$. La construction du dictionnaire multivarié est identique à celle correspondant au cas univarié. Elle est obtenue en insérant dans chaque atome (colonne) les hyperparamètres multivariés de chaque image radar. La dimension de chaque vecteur caractéristique est égale dans ce cas à $m = nbp \times 6J + nbs \times 3J$, avec nbp




FIGURE 5.15 – Ajustement de la PDF empirique de la copule Gaussienne (trait en bleu) à la PDF estimée (trait en rouge) des amplitudes des coefficients d'ondelettes inter-orientation d'une image ISAR. La première colonne présente le cas d'une loi marginale de type Gamma (GC-Gam). La deuxième colonne illustre l'utilisation de la distribution Weibull comme loi marginale (GC-Wbl).




FIGURE 5.16 – Ajustement de la PDF empirique de la copule Gaussienne (trait en bleu) à la PDF estimée (trait en rouge) des amplitudes des coefficients d'ondelettes inter-orientation d'une image SAR. La première colonne présente le cas d'une loi marginale de type Gamma (GC-Gam). La deuxième colonne illustre l'utilisation de la distribution Weibull comme loi marginale (GC-Wbl).

est le nombre des paramètres statistique de loi marginale (il est égale à 2 dans le cas des lois Gamma ou Weibull), nbs le nombre d'éléments de la matrice covariance du modèle multivarié ($= 2 \times 2 = 4$ dans le cas d'un modèle bivarié) et J le nombre d'échelles de décomposition.

La technique adoptée pour pondérer le dictionnaire statistique est la même que celle décrite dans la sous-section 5.3.3. Par conséquent, nous avons ajouté l'information de localité au dictionnaire en calculant sa matrice de similarité avec tous les vecteurs d'apprentissage. Cela est effectué en utilisant la distance donnée par l'équation (5.10). Dans le cas de la modélisation multivariée, la KLD (d_{KLD}) est calculée entre les statistiques jointes :

$$KLD(f_1 \| f_2) = \int_{+\infty}^{-\infty} \dots \int_{+\infty}^{-\infty} f_1(\vec{x}) \ln \frac{f_1(\vec{x})}{f_2(\vec{x})} d\vec{x} \quad (5.24)$$

À partir de l'équation (5.24), les auteurs dans [Lasmar et Berthoumieu, 2014] ont proposé une formule analytique de la KLD entre d copules Gaussiennes. Sa formule est donnée par :

$$\begin{aligned} KLD(f_1(\vec{x}; p_1) \| f_2(\vec{x}; p_2)) &= \sum_{i=1}^d KLD \left(f_{1,i}(x'_i; \theta_i^{(1)}) \| f_{2,i}(x'_i; \theta_i^{(2)}) \right) + \\ &0.5 \left(Tr(\Sigma_2^{-1} \Sigma_1) + \ln \left(\frac{|\Sigma_2|}{|\Sigma_1|} \right) - d \right) \end{aligned} \quad (5.25)$$

où $Tr(\cdot)$ désigne la somme des coefficients diagonaux de la matrice.

En outre, la formule de KLD entre deux copules Gaussiennes est la somme de la KLD entre les statistiques marginales et les statistiques jointes. En effet, la KLD entre deux modèles bivariés GC-Gam ($d = 2$) se définit par :

$$\begin{aligned} KLD_{GC-Gam}(f_1(\vec{x}; p_1) \| f_2(\vec{x}; p_2)) &= \sum_{i=1}^2 KLD_{Gamma} \left(f_{1,i}(x'_i; b_i^{(1)}, a_i^{(1)}) \| f_{2,i}(x'_i; b_i^{(2)}, a_i^{(2)}) \right) + \\ &0.5 \left(Tr(\Sigma_2^{-1} \Sigma_1) + \ln \left(\frac{|\Sigma_2|}{|\Sigma_1|} \right) - 2 \right) \end{aligned} \quad (5.26)$$

La KLD entre deux modèles bivarié GC-Wbl ($d = 2$) est aussi obtenue à partir de l'équation (5.25) :

$$\begin{aligned} KLD_{GC-Wbl}(f(\vec{x}; p_1) \| g(\vec{x}; p_2)) &= \sum_{i=1}^2 KLD_{Weibull} \left(f_{1,i}(x'_i; \tau_i^{(1)}, \mu_i^{(1)}) \| f_{2,i}(x'_i; \tau_i^{(2)}, \mu_i^{(2)}) \right) + \\ &0.5 \left(Tr(\Sigma_2^{-1} \Sigma_1) + \ln \left(\frac{|\Sigma_2|}{|\Sigma_1|} \right) - 2 \right) \end{aligned} \quad (5.27)$$

Finalement, la distance entre une image radar de test (caractérisée par son vecteur caractéristique y) et une image radar d'apprentissage (caractérisée par son vecteur caractéristique V_p) est :

$$d_{KLD}(y, V_p) = \sum_{t=1}^{3J} KLD(f_1(RVM^{\text{test},t}; p^{\text{test},t}) \| f_2(RVM^{\text{train},t}; p^{\text{train},t})) \quad (5.28)$$

5.5 Reconnaissance via la classification parcimonieuse

Dans la phase de classification, pour reconnaître une image radar de test représentée par son vecteur caractéristique y , nous calculons dans un premier temps le dictionnaire statistique pondéré A' capable de bien approximer y . Nous appliquons par la suite la méthode SRC (Cf. l'algorithme 3.1, chapitre 3) en utilisant le dictionnaire pondéré. Ainsi, l'objectif est de représenter le vecteur de test y comme suit :

$$y = A'x \quad (5.29)$$

Le vecteur $x \in \mathbb{R}^n$ doit être le plus parcimonieux possible. Pour atteindre cela, un problème d'optimisation similaire à celui de l'équation (3.4) doit être résolu :

$$\hat{x} = \underset{x}{\operatorname{argmin}} \|x\|_1 \quad \text{sous la contrainte} \quad \|y - A'x\|_2 \leq \epsilon \quad (5.30)$$

Le dictionnaire pondéré A' va contribuer à améliorer davantage le caractère parcimonieux du vecteur $\hat{x}$. Après l'obtention de la solution optimale $\hat{x}$, la reconstruction du vecteur de test pour chaque classe c est :

$$\hat{y}_c = A'\delta_c(\hat{x}) \quad (5.31)$$

Finalement, la classe de y sera la classe qui a le minimum du résidu r entre y et $\hat{y}_c$ (Cf. Équation 3.12).

Alors que la méthode SRC se base uniquement sur les informations de linéarité, le WSRC ajoute aussi l'aspect de la localité. Dans le cas idéal, le WSRC donnera des poids nuls à tous les atomes sauf ceux qui appartiennent à la même classe du vecteur de test à classer.

5.6 Application et résultats

5.6.1 Présentation de la démarche d'application et d'évaluation

Comme indiqué précédemment et afin de valider l'approche proposée WSRC-KLD, nous utilisons les deux types de base de données décrites dans la sous-section 2.3.3. Pour chaque image radar considérée (ISAR ou SAR), le vecteur caractéristique est calculé en utilisant une modélisation statistique dans le domaine des ondelettes complexes. Dans cette optique, la méthode DT-CWT avec trois échelles de décomposition a été utilisée. Pour la première échelle, le filtre (13, 19)-tap near-orthogonal est appliqué. Tandis que pour les deux dernières échelles, le filtre Q-shift (14,14)-tap est utilisé. En effet, le choix de ces deux filtres a été adopté et proposé dans les travaux de [Kingsbury, 2001] et de [Kwitt et Uhl, 2010]. Après cela, nous avons estimé les paramètres statistiques en utilisant soit la modélisation univariée (Gamma ou Weibull) soit la modélisation multivariée (GC-Gam ou GC-Wbl). La concaténation de ces paramètres statistiques (univariés ou multivariés) pour toutes les sous-bandes de toutes les échelles de décomposition nous a

fournit le vecteur caractéristique décrivant chaque image radar. Nous rappelons que la dimension de ce vecteur descripteur est égale à :

- $m = nbp \times 6 \times J$ dans le cas de la modélisation univariée, avec $nbp = 2$ est le nombre de paramètres statistiques des lois marginales et J le nombre d'échelle de décomposition.
- $m = nbp \times 6 \times J + nbs \times 3 \times J$ dans le cas de la modélisation multivariée, avec $nbs = 4$ est le nombre d'éléments dans la matrice de covariance bivariée.

La dimension considérée de chaque vecteur caractéristique est données dans le Tableau 5.4.

Échelles de décomposition	1 échelle	2 échelles	3 échelles
Modélisation univariée (Gamma ou Weibull)	m = 12	m = 24	m = 36
Modélisation multivariée (GC-Gam ou GC-Wbl)	m = 24	m = 48	m = 72

TABLE 5.4 – Dimensions des descripteurs correspondants aux modélisations univariées ou multivariées pour différentes échelles de décomposition.

Pour valider notre démarche et évaluer les performances de la méthode proposée, une comparaison des résultats est réalisée avec cinq autres méthodes de classification sur le même vecteur caractéristique. Pour mener à bien cette comparaison, les méthodes de classification considérées sont :

- KPPV [Cover et Hart, 1967] : le principe de ce classifieur est décrit dans la section B.1 de l'annexe B. Le nombre de voisins K est sélectionné empiriquement. Il est égal à 3 pour les images ISAR et 9 pour les images SAR.
- SVM [Vapnik, 1995] : c'est un classifieur basé sur les noyaux. Plus de détails sur cette méthode peuvent être trouvés dans la section B.2 de l'annexe B. Nous utilisons le noyau linéaire pour les deux bases de données.
- SRC [Wright *et al.*, 2009a] : cela correspond à la classification basée sur la parcimonie avec un dictionnaire global pour toutes les images de test à classifier.
- WSRC1 [Lu *et al.*, 2013] : un dictionnaire local pondéré est utilisé dans cette méthode pour chaque vecteur de test à classifier. Cette pondération est obtenue par la distance suivante : $Dist(y, V_p) = \|y - V_p\|$
- WSRC2 [Fan *et al.*, 2015] : cette méthode est une amélioration de celle présentée dans [Lu *et al.*, 2013]. Les auteurs proposent de mesurer le poids en utilisant la distance suivante : $Dist(y, V_p) = \exp\left(\frac{-d_{ED}(y, V_p)^2}{2\varrho^2}\right)$, avec ED est la distance Euclidienne et ϱ est la variance qui est obtenue en calculant la moyenne des distances Euclidiennes des descripteurs d'apprentissage. Dans notre expérimentation, $\varrho = 1.65$ pour les images ISAR et $\varrho = 0.21$ pour les images SAR.

Par la suite, nous nous limitons dans l'évaluation par taux de reconnaissance et matrices de confusion, à une comparaison restreinte sur les meilleurs classifieurs.

5.6.2 Résultats de reconnaissance en considérant les images ISAR

Dans le cas des images ISAR, nous répartissons la base de données globale (1944 images) en base de test et base d'apprentissage en utilisant une validation croisée de type *Hold-Out Cross-Validation*. Dans la Figure 5.17, nous représentons graphiquement l'influence de la taille de la base d'apprentissage (nombre d'atomes dans le dictionnaire) sur le taux de reconnaissance. Nous pouvons signaler que la taille de la base d'apprentissage a une influence sur le taux de classification. En n'utilisant que 10% pour l'apprentissage (194 images ISAR), notre approche atteint un taux de reconnaissance à 83% pour 1750 images ISAR dans la base de test. Pour la suite, nous avons partitionné la base d'images ISAR avec 40% (780 images ISAR) pour la base d'apprentissage et 60% (1164 images ISAR) pour la base de test.




FIGURE 5.17 – Variation du taux de reconnaissance en fonction du nombre d'atomes statistiques dans le dictionnaire pour le cas des images ISAR. La première et la deuxième ligne correspondent respectivement aux dictionnaires statistiques univarié et multivarié.

Nous présentons dans le Tableau 5.5 les taux de classification obtenus pour les différentes méthodes utilisées. À partir du Tableau 5.5, nous pouvons dresser quelques remarques et observations :

- L'amélioration du taux de classification avec l'augmentation du nombre d'échelles de décomposition.
- Les classifieurs parcimonieux (SRC, WSRC1, WSRC2 et WSRC-KLD) sont moins

TABLE 5.5 – Taux de reconnaissance (%) des images ISAR pour différentes méthodes statistiques en comparaison avec la méthode proposée WSRC-KLD.

Modèles statistiques	Échelles de décomposition											
	1 échelle				2 échelles				3 échelles			
	Univariés		Multivariés		Univariés		Multivariés		Univariés		Multivariés	
	Weibull	Gamma	GC-Wbl	GC-Gam	Weibull	Gamma	GC-Wbl	GC-Gam	Weibull	Gamma	GC-Wbl	GC-Gam
KPPV	79.25	73.93	80.01	73.75	92.11	86.36	90.65	84.82	93.65	90.48	94.51	87.99
SVM	45.45	48.71	50.17	50.77	66.29	72.81	65.27	74.96	82.42	87.22	85.24	85.84
SRC	30.96	42.19	86.28	81.13	73.67	80.79	90.25	93.74	93.56	95.19	93.57	96.48
WSRC1	32.42	41.20	66.38	78.30	73.67	81.39	88.42	86.62	94.17	95.45	91.34	91.51
WSRC2	30.27	42.28	65.58	79.50	72.73	79.41	90.13	90.57	93.91	95.79	93.48	92.11
WSRC-KLD (méthode proposée)	30.96	42.02	69.75	88.67	73.76	81.39	89.97	90.82	93.74	96.91	97.17	97.68

performants en utilisant une seule échelle de décomposition. Cela est dû à la petite dimension du descripteur qui est égale à 12 dans le cas univarié et 24 dans le cas multivarié.

- L'utilisation de la modélisation multivariée présente des performances meilleures que la modélisation univariée. Cela montre l'existence d'une forte dépendance entre les sous-bandes complexes des images ISAR.
- L'utilisation de la distribution Gamma comme modèle univarié ou loi marginale du modèle multivarié est plus performante que la distribution de Weibull. Cela est en adéquation avec les petites valeurs du KS obtenues dans les tableaux 5.2 et 5.3.
- En utilisant le modèle multivariée GC-Gam obtenus sur les trois échelles de décomposition, le taux de reconnaissance le plus faibles (85.84%) est obtenu par le classifieur SVM qui nous conforte à dire que le descripteur utilisé décrit d'une manière discriminante les images ISAR.
- Les classifieurs parcimonieux sont dans la plupart des cas plus performants que les deux classifieurs KPPV et SVM. Ce constat prouve l'intérêt de l'utilisation de cette famille de méthodes de classification.
- Généralement, les différentes versions de WSRC fournissent des performances supérieures que l'algorithme SRC. Cela est dû au fait que la méthode WSRC exploite aussi l'information de la localité des données (similarité entre les vecteurs caractéristiques).
- La pondération utilisée dans les classifieurs WSRC1 et WSRC2 fournissent dans le cas de la configuration choisie des taux de reconnaissance plus faibles que la méthode proposée (WSRC-KLD). Cela est dû à la distance utilisée dans ces deux classifieurs qui n'est pas adaptée avec la nature du descripteur utilisé.
- La méthode proposée présente des performances satisfaisantes sur la base d'images ISAR avec une amélioration en taux de reconnaissance obtenus pour les cinq autres méthodes. Par exemple, l'utilisation de la loi GC-Gam avec trois échelles de décomposition conduit à un taux de reconnaissance de 97.68%. Cela montre la supériorité du descripteur utilisé ainsi que le gain gagné en termes de taux de reconnaissance en intégrant la KLD dans le classifieur WSRC.

Nous illustrons dans la Figure 5.18 les matrices ds confusion de l'utilisation du modèle

multivarié GC-Gam à l'échelle 3. La méthode proposée conduit à des taux de reconnaissance supérieurs à 92.78% pour les 12 classes. En plus de ça, nous obtenons des taux de reconnaissance de 100% pour trois classes qui sont : F117, Rafale et F14. Nous soulignons aussi que la plus grande erreur de classification obtenue est de l'ordre de 5% qui est due à une conséquence de la confusion entre les classes F15 et A10.




FIGURE 5.18 – Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas des images ISAR

5.6.3 Résultats de reconnaissance en considérant les images SAR

Nous tenons à rappeler que, pour le cas des images SAR, la base de donnée MSTAR est déjà partitionnée en bases d'apprentissage et de test (Cf. le paragraphe 2.3.3.2). Les résultats de reconnaissance donnés par les différentes méthodes en comparaison avec la méthode WSRC-KLD proposée sont présentés dans le Tableau 5.6.

Dans l'ensemble, l'augmentation de niveau de décomposition conduit à une discrimination du descripteur de chaque image SAR et par conséquent permet d'améliorer davantage le taux de reconnaissance.

TABLE 5.6 – Taux de reconnaissance (%) des images SAR pour différentes méthodes statistiques en comparaison avec la méthode proposée WSRC-KLD.

Version MSTAR	Modèles statistiques	Échelles de décomposition											
		1 échelle				2 échelles				3 échelles			
		Univariés		Multivariés		Univariés		Multivariés		Univariés		Multivariés	
		Weibull	Gamma	GC-Wbl	GC-Gam	Weibull	Gamma	GC-Wbl	GC-Gam	Weibull	Gamma	GC-Wbl	GC-Gam
SOC	KPPV	66.23	64.33	71.83	74.05	67.58	68.73	69.48	75.05	68.66	69.20	61.85	57.77
	SVM	62.07	57.56	74.01	72.41	69.32	66.96	75.73	75.81	71.75	73.81	80.15	82.04
	SRC	23.14	34.03	20.14	20.58	62.89	62.58	20.20	18.52	78.43	79.68	58.13	57.81
	WSRC1	24.86	34.20	34.17	36.48	63.04	63.75	40.03	38.18	80.03	80.17	60.27	59.05
	WSRC2	27.13	35.24	74.63	84.78	64.29	66.32	76.83	83.79	80.11	80.26	69.73	68.53
	WSRC-KLD (méthode proposée)	28.01	36.57	74.63	78.43	65.73	69.07	76.83	83.79	80.95	81.04	78.68	84.68
EOC-1	KPPV	67.47	69.23	67.90	69.45	69.74	73.18	69.45	73.33	70.84	74.21	72.93	74.36
	SVM	72.01	74.58	71.86	74.73	74.94	73.33	76.19	72.45	74.94	74.95	76.92	74.43
	SRC	55.45	46.95	56.77	56.55	53.04	46.08	82.82	54.21	53.04	56.77	54.95	55.67
	WSRC1	30.32	40	37.36	44.17	33.40	40.21	34.65	35.75	23.44	57.12	26.66	41.75
	WSRC2	60.14	42.31	63.29	67.38	69.15	75.60	69.74	76.77	71.79	58.17	71.21	76.41
	WSRC-KLD (méthode proposée)	69.87	69.81	69.01	71.64	72.63	75.31	73.14	74.79	77.69	78.38	77.51	80.13
EOC-2 (15°)	KPPV	86.13	90.87	86.49	90.99	85.15	89.78	85.52	90.14	79.78	78.47	87.23	78.58
	SVM	90.65	89.75	91.24	91.72	84.67	90.63	86.25	92.45	85.94	92.07	86.01	92.45
	SRC	52.80	55.47	56.93	58.76	50.86	50.60	53.28	52.36	55.58	49.63	49.64	50.36
	WSRC1	40.14	38.32	41.64	34.31	31.02	29.93	29.68	30.90	26.88	29.44	28.34	27.13
	WSRC2	88.56	91.24	88.44	91.36	86.98	91.85	87.59	92.70	89.90	85.88	90.01	87.10
	WSRC-KLD (méthode proposée)	89.17	91.97	91.85	81.84	82.23	90.75	84.55	92.33	82.36	87.18	90.13	93.67
EOC-2 (30°)	KPPV	76.90	76.01	76.89	76.05	79.80	78.79	79.36	78.68	82.03	71.65	82.85	72.21
	SVM	79.24	73.43	79.35	75.44	82.36	79.24	82.92	79.69	83.04	86.13	83.37	85.38
	SRC	40.51	48.77	45.87	45.64	42.85	44.30	42.74	43.19	44.09	42.85	45.53	43.74
	WSRC1	50.19	52.12	64.18	57.27	52.14	45.01	50.43	64.15	50.63	46.01	37.50	41.29
	WSRC2	68.18	60.53	70.03	69.33	70.01	76.33	69.18	77.90	78.68	74.10	79.01	74.88
	WSRC-KLD (méthode proposée)	71.87	80.72	76.01	80.94	72.43	83.59	71.43	83.03	80.30	85.15	86.04	86.27
EOC-2 (45°)	KPPV	55.48	60.45	55.40	60.89	66.02	56.27	65.94	56.97	51.74	49.04	51.74	49.12
	SVM	64.98	63.76	64.87	64.11	64.81	64.25	64.98	64.43	64.28	64.37	64.45	64.54
	SRC	44.43	35.02	41.89	34.93	38.07	38.76	38.24	38.59	40.50	36.49	38.32	38.41
	WSRC1	43.47	38.32	46.34	37.28	44.25	38.15	44.34	40.33	34.14	31.35	34.49	32.14
	WSRC2	65.24	62.37	64.80	62.63	67.13	60.62	67.16	61.24	61.58	51.04	61.67	51.04
	WSRC-KLD (méthode proposée)	61.24	62.03	64.89	63.50	63.76	64.81	65.18	64.63	64.90	66.55	66.73	67.59

Nous remarquons aussi que la modélisation multivariée dépasse celle univariée ce qui montre l'intérêt d'introduire l'information de dépendance dans le processus de modélisation. En plus, on voit clairement que l'utilisation de Gamma comme modèle univarié ou loi marginale de la copule Gaussienne présente des performances supérieures à celles données en utilisant la loi de Weibull. Mise à part la méthode proposée, le modèle GC-Gam donne de meilleurs résultats en combinaison avec le classifieur SVM. Par ailleurs, les classifieurs parcimonieux pondérés WSRC1 et WSRC2 n'arrive pas à bien classifier les images SAR vu que la distance qu'elles adoptent ne prenne pas en considération la nature du descripteur.

En analysant ces résultats, nous constatons que le modèle GC-Gam en combinaison avec WSRC-KLD donne les performances les plus élevées. Ceci montre que l'approche statistique et parcimonieuse est fructueuse et donne des résultats encourageants. La Figure 5.19 présente les différentes matrices de confusion de la méthode proposée ainsi que celles d'autres méthodes sur la version SOC de la base de données MSTAR. Nous remarquons que la pondération utilisée dans la méthode WSRC2 donne naissance à de grandes erreurs de classification. Néanmoins, la méthode SVM reste une méthode très compétitive

par rapport à la méthode proposée et l'excède dans le taux de reconnaissance de quatre classes. Cependant, la méthode proposée donne des taux de reconnaissance supérieurs au niveau global.




FIGURE 5.19 – Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas de la version SOC de la base données MSTAR.

Nous illustrons dans la Tableau 5.7 les matrices de confusion produites par les différentes méthodes en comparaison avec la méthode proposée dans le cas de la version EOC-1 de la base données MSTAR. Il est observé que la méthode proposée donne le taux de reconnaissance le plus élevé pour deux classes : BMP2 et T72. Par contre, la méthode SVM donne un taux de reconnaissance de 75.51% pour la classe BTR70 ce qui correspond à une amélioration de 7.14% par rapport à la méthode proposée. Nous notons aussi que pour les images SAR considérées, les taux de reconnaissances par classe ne sont pas autant balancés pour les différentes méthodes. Cela est traduit par un grand écart des taux de reconnaissances entre la classe T72 et les classes BMP2 et BTR70.

TABLE 5.7 – Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas de la version EOC-1 de la base données MSTAR.

	GC-Gam+SVM (74.43)			GC-Gam+WSRC2 (76.41)			GC-Gam+WSRC-KLD (méthode proposée) (80.13)		
	BMP2	BTR70	T72	BMP2	BTR70	T72	BMP2	BTR70	T72
BMP2	52.64	32.20	15.16	58.26	24.70	17.04	73.05	12.26	14.69
BTR70	19.39	75.51	5.10	20.41	71.43	8.16	19.39	68.37	12.25
T72	1.03	2.92	96.05	2.41	1.20	96.39	0.69	0.34	98.97

Nous donnons dans le Tableau 5.8, les matrices de confusions dans le cas de la version EOC-2 de la base données MSTAR. Ces dernières correspondent d'une part à celle de la méthode proposée et d'autre part à celles des autres méthodes compétitives. Dans la plupart des cas, la méthode proposée donne des taux de reconnaissances par classe supérieurs en comparaison à ceux donnés par les autres méthodes. Par ailleurs, l'utilisation d'un angle de dépression de 45° pour les images de test génère un taux de reconnaissance très faible pour la classe ZSU234. Par conséquent, le taux d'erreur est très élevé par cette classe à cause de sa grande confusion avec la classe 2S1. Pour ce cas de figure, en utilisant la méthode proposée nous obtenons un taux de reconnaissance de 100% pour la classe 2S1 et de 96.69% pour la classe BRDM2. Mais le taux de reconnaissance global est relativement moyen et vaut 67.59% à cause du faible taux de reconnaissance fourni par la classe ZSU234 qui est égal à 15.17%.

TABLE 5.8 – Matrices de confusion pour les différentes méthodes de classification dans l'échelle 3 en utilisant le descripteur obtenu par GC-Gam : cas de la version EOC-2 de la base données MSTAR.

		GC-Gam+WSRC2 (87.10)			GC-Gam+SVM (92.45)			GC-Gam+WSRC-KLD (méthode proposée) (93.67)		
		2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234	2S1	BRDM2	ZSU234
15°	2S1	79.20	15.69	5.11	81.02	0.73	18.25	83.94	0.36	15.69
	BRDM2	4.38	88.69	6.93	0	99.63	0.36	0	98.91	1.09
	ZSU234	6.20	0.37	93.43	3.28	0	96.72	1.82	0	98.18
		GC-Gam+WSRC2 (74.88)			GC-Gam+SVM (85.38)			GC-Gam+WSRC-KLD (méthode proposée) (86.27)		
30°	2S1	71.23	1.01	27.76	68.23	0	31.77	66.88	0	33.11
	BRDM2	18.79	76.85	4.36	1.45	93.93	4.62	0	97.32	2.68
	ZSU234	19.40	4.01	76.59	3.01	3.01	93.98	5.35	0	94.65
		GC-Gam+WSRC2 (51.39)			GC-Gam+SVM (64.54)			GC-Gam+WSRC-KLD (méthode proposée) (67.59)		
45°	2S1	96.04	1.98	1.98	100	0	0	100	0	0
	BRDM2	36.17	41.37	22.46	0.71	99.05	0.24	0	96.69	3.31
	ZSU234	69.43	1.19	29.38	95.50	0	4.50	84.36	0.47	15.17

5.7 Synthèse

Dans ce chapitre, nous avons présenté l'application de la deuxième approche développée qui consiste en une classification parcimonieuse pondérée des images SAR et ISAR. Pour ce faire, nous avons proposé l'utilisation d'un dictionnaire statistique. La motivation derrière ce choix est d'une part la construction d'un dictionnaire redondant (la dimension de chaque atome est trop petite par rapport aux nombres d'atomes). D'autre part, le descripteur adopté a montré son aptitude à bien caractériser l'image radar. Pour la pondération de ce dictionnaire, une mesure de similarité entre les paramètres statistiques de chaque atome a été utilisée. Les résultats obtenus en considérant les deux types d'images (ISAR et SAR) ont montré que l'approche multivariée présente une supériorité par rapport à celle univariée. En effet, la combinaison du modèle GC-Gam avec le classifieur parcimonieux pondéré par la KLD (GC-Gam+WSRC-KLD) donne les meilleurs résultats en comparaison avec ceux donnés par les autres méthodes. Nous avons adopté trois échelles de décompositions pour être en adéquation avec les recommandations présentées dans [Do et Vetterli, 2002]. Ainsi, les recommandations retenues préconisent l'emploi des sous-bandes de tailles plus grandes que 16×16 pixels afin de s'assurer de la consistance de l'estimation des paramètres statistiques.

Le Tableau 5.9 donne une synthèse des taux de reconnaissances obtenus pour les différentes bases de données testées. En se basant sur ces résultats, nous remarquons que la base de données des images ISAR donne des résultats supérieurs en terme du taux de reconnaissance en comparaison à ceux obtenus par les images SAR. Cela est dû à la présence forte du bruit dans le cas des images SAR.

TABLE 5.9 – Synthèse des résultats obtenus pour les images SAR et ISAR en utilisant la méthode proposée (GC-Gam+WSRC-KLD) au troisième échelle de décomposition.

	Images ISAR	Images SAR				
		SOC	EOC-1	EOC-2 (15°)	EOC-2 (30°)	EOC-2 (45°)
Taux de reconnaissance (%)	97.68	84.68	80.13	93.67	86.27	67.59

Des taux de reconnaissances relativement faibles d'environ 80.13% 67.59% sont obtenus par les versions EOC-1 et EOC-2 (45°) respectivement. Cela est à cause du grand nombre d'images de test (1365 images) qui présente plus que le double du cardinal des images d'apprentissage (689 images) pour le cas d'EOC-1. D'autre part, le faible taux de reconnaissance généré par la version EOC-2 (45°) est dû principalement à la grande différence ($=28^\circ$) entre les angles de dépression utilisés pour l'apprentissage et celui du test. Généralement, le taux de reconnaissance se dégrade si la différence entre les angles de dépression des images d'apprentissage et de test augmente.



CONCLUSION GÉNÉRALE ET PERSPECTIVES

La reconnaissance de cibles radar est considérée comme l'une des problématiques les plus complexes de la télédétection. L'évolution incessante des systèmes radar et la diversité des modes d'acquisition ont rendu cette tâche très difficile. C'est la raison pour laquelle plusieurs travaux scientifiques proposent des approches méthodologiques afin de tenter de résoudre ce problème. Depuis l'acquisition des images radar, différents chercheurs ont tiré profit de cette avancée pour les exploiter dans le cadre de cette discipline. Et ceci avec des ouvertures sur la reconnaissance de forme et l'intelligence artificielle. Néanmoins, la plupart des méthodes propose des processus de reconnaissance pour une application définie et pour un type d'images. À travers ce travail, nous avons tenté de proposer des méthodes innovantes permettant d'améliorer le processus de reconnaissance en tenant compte à la fois de la précision des méthodes mais aussi du temps de calcul. Ainsi, nous avons proposé une méthodologie originale basée sur la classification parcimonieuse. Et cette méthodologie a été évaluée via deux bases de données d'images radar. Une première concerne les images ISAR récoltées dans la chambre anéchoïque de l'ENSTA Bretagne. Quant à la deuxième base de données (MSTAR), elle est constituée d'images SAR. Dans ce cadre, plusieurs avancées ont été notées à travers les travaux présentés dans les chapitres 4 et 5.

Nous avons présenté dans le chapitre 2 les étapes du schéma global d'un processus de reconnaissance de cibles. Dans un premier temps, nous avons exposé quelques principes associés au système radar ainsi que la description des deux bases de données d'images exploitées dans ce travail. Ainsi, nous avons souligné la différence entre les modes d'acquisition des images ISAR et des images SAR. Ensuite, nous avons dressé le principe et la description synthétique des trois principales composantes d'un processus de reconnaissance de cibles qui sont : le traitement, l'extraction des caractéristiques et la classification. À l'issue de cette présentation générale sur différentes notions, nous avons constaté que les images ISAR et SAR issues des deux bases de données se différencient sur différents aspects. Par exemple, l'information fournie par l'ombre ne peut être exploitée que pour le cas des images SAR. Cela nous a conduit à pencher sur des méthodes qui ont prouvé leurs robustesses dans un type d'image radar et ensuite les évaluer sur l'autre type d'images. Dans cette optique, nous nous sommes focalisés sur la classification parcimonieuse qui

est largement utilisée dans différents domaines et en particulier dans le cas des images SAR. Par conséquent, l'un des objectifs importants des travaux réalisés portait sur l'étude et l'apport de la classification parcimonieuse dans la problématique de reconnaissance de cibles à partir des images radar. En plus de son application, plusieurs améliorations de cette méthode ont été proposées. Ces améliorations concernent principalement la manière de composition du dictionnaire qui est indispensable pour la résolution du problème d'optimisation parcimonieux. Par définition, ce dictionnaire est une structure matricielle composée de plusieurs atomes contenant les descripteurs des images de la base d'apprentissage. Pour une meilleure introduction dans la problématique de reconnaissance, le principe, les concepts et le lien de la parcimonie avec la classification ont été présentés dans le chapitre 3.

Via le travail réalisé, on peut noter plusieurs avancées. Ainsi, dans le chapitre 4, nous avons proposé un nouveau dictionnaire composé des descripteurs SIFT saillants qui a été exploité par la classification parcimonieuse multitâches. La méthode proposée est abrégée par MSKD+MSRC. L'idée initiale était d'adopter une description locale des images ISAR et SAR. Nous avons constaté que le descripteur local le plus utilisé dans différentes applications de traitement d'image est la méthode SIFT. Par contre cette méthode est sévèrement critiquée en télédétection et plus précisément en imagerie radar. Cela vient du fait de la multitude de points clés générés par cette méthode. Ce constat a été aussi noté et vérifié visuellement sur les deux types d'images utilisés. En effet, les points clés sont disséminés dans les différentes zones de l'image radar. Par conséquent, l'image radar est représentée par un nombre non négligeable d'atomes ce qui va produire des dictionnaires de grande dimension. Notre objectif était de concentrer ces points clés dans la zone d'intérêt qui contient la cible et par conséquent réduire la taille du dictionnaire. Pour cette finalité, nous avons proposé d'appliquer la saillance visuelle sur les images radar. Cela nous a conduit à produire des images radar segmentées. Après cela, la méthode SIFT a été appliquée. Comme résultat, seuls les points clés SIFT localisés dans la cible sont maintenus. Quant à la phase de reconnaissance, nous avons considéré chaque descripteur SIFT saillant étant une tâche qui est classifiée en utilisant la méthode SRC. Ensuite, en suivant le principe de la classification multitâche, nous avons additionné les résidus produits par les SRC de toutes les tâches de chaque image radar. La classe qui a produit le résidu le plus faible est affectée au vecteur de test. En termes de vecteur caractéristique, la méthode proposée a été comparée avec la méthode SIFT (sans filtrage). Pour la reconnaissance, une comparaison a été faite avec la méthode du matching qui reste la méthode de classification la plus utilisée pour reconnaître les descripteurs SIFT. Nous avons prouvé via les images considérées, d'une part que la réduction de points clés SIFT a contribué à la fois à l'amélioration des performances de la reconnaissance et à l'accélération du temps de calcul dans le processus de reconnaissance. D'autre part, les résultats ont montré que l'approche parcimonieuse multitâche des descripteurs SIFT a dépassé largement la méthode du matching. Cependant, cette approche a deux limites majeures. Tout d'abord, plusieurs atomes représentent la même image radar, et ceci malgré que nous avons réussi à diminuer

leurs nombres. Ensuite, les images radar de test sont toutes classifiées en utilisant le même dictionnaire.

Pour pallier aux limites de cette première avancée, nous avons tenté, à travers l'approche WSRC-KLD présentée dans le chapitre 5, de représenter l'image radar par un seul atome et de concevoir un dictionnaire spécifique pour chaque image radar de test à classifier. En ce qui concerne la construction du dictionnaire, nous avons adopté une approche statistique dans le domaine des ondelettes complexes. Dans un premier lieu, nous avons appliqué la méthode DT-CWT sur chaque image radar pour générer plusieurs sous-bandes composées des coefficients complexes. Nous nous sommes focalisés sur l'information de l'amplitude de ces coefficients. Dans le cadre d'une modélisation statistique univariée, l'amplitude de chaque sous-bande a été considérée comme une réalisation d'une variable aléatoire. Après avoir justifié l'aspect asymétrique et leptokurtique du vecteur aléatoire considéré, nous avons opté pour l'utilisation des distributions Weibull et Gamma comme modèles statistiques non-Gaussiens. Ainsi, les paramètres statistiques estimés, pour chacune des distributions, sont considérés comme atome de l'image radar. Enfin, les atomes de toutes les images d'apprentissage construiront le dictionnaire statistique univarié. Dans la deuxième partie de cette avancée scientifique, nous avons pris en considération la dépendance entre les amplitudes des sous-bandes complexes. Cela nous a amené à étudier leurs statistiques jointes dans un cadre statistique multivarié. Tout d'abord, nous avons considéré des vecteurs bivariés composé chacun par les amplitudes des coefficients de deux orientations d'une même échelle de décomposition. Ensuite, nous avons mis en évidence l'importance de leurs dépendances inter-orientation. Cela a été vérifié en utilisant le test Chi-plot. Pour décrire leurs statistiques jointes, nous avons considéré les modèles multivariés à copule Gaussienne. Cela nous a permis de construire deux modèles statistiques bivariés basés sur la copule Gaussienne et les distributions Gamma ou Weibull comme marginales. Par conséquent, un dictionnaire multivarié est construit. Pour les différents modèles statistiques considérés, nous avons étudié leurs qualités d'ajustement d'une manière visuelle et ensuite quantitativement en utilisant le test KS. Cela a montré un bon ajustement de ces modèles avec les vecteurs aléatoires considérés. Étant donné une image radar de test à reconnaître, nous avons calculé son descripteur en s'appuyant sur la même approche suivie pour les images d'apprentissage. Comme énoncé dans la littérature, il n'existe que quelques atomes qui contribuent à une bonne décomposition parcimonieuse d'un vecteur donné. Ainsi, nous avons essayé de sélectionner les atomes les plus pertinents. Pour ce faire, nous avons multiplié chaque atome par un poids. Ce dernier représente son degré d'importance à représenter le vecteur de test. Ce poids a été calculé en utilisant une mesure de similarité entre le vecteur de test et chacun des atomes. Vue la nature statistique des atomes, nous avons opté à utiliser une mesure de similarité qui intègre la KLD entre les paramètres statistiques univariés ou multivariés. Pour reconnaître le vecteur de test, la méthode SRC a été appliquée en exploitant le dictionnaire statistique pondéré. Ces étapes correspondent au principe de la classification parcimonieuse pondérée WSRC. Nous avons consacré la fin de ce chapitre à l'évaluation des performances de la

méthode proposée. Les différentes applications et simulations que nous avons menées ont montré, d'une part la prédominance du dictionnaire multivarié en comparaison avec celui univarié. D'autre part, la méthode WSRC a montré de bonnes performances en comparaison avec d'autres méthodes de classification y compris SRC. Ce qui prouve l'importance de la construction d'un dictionnaire spécifique pour chaque vecteur de test. En plus de ça, la mesure de similarité proposée comme pondération a conduit à une considérable amélioration par rapport à d'autres pondérations utilisées dans la littérature.

Plusieurs voies peuvent être envisagées dans le sillage de ce travail. Nous en esquissons ici celles qui paraissent les plus pertinentes. Des améliorations importantes sont envisageables par rapport à la méthode MSKD+MSRC proposée dans le chapitre 4, notamment au niveau du choix des méthodes de la description locale de l'image et de la saillance visuelle. Dans le même contexte, une classification jointe pondérée WJSRC (Weighted Joint Sparse Representation based-Classification) entre les descripteurs locaux saillants peut être envisagée. Dans le sillon de la méthode WSRC-KLD présentée dans le chapitre 5, nous pensons paramétrer davantage ses degrés de liberté. Tout d'abord, il serait important d'étudier d'autres familles d'ondelettes à l'instar de celles géométriques adaptatives (contourlettes, curvelettes, ...). Ensuite, l'utilisation d'une autre famille d'ondelettes va exiger de choisir d'autres modèles statistiques bien adéquats. Un autre point d'intérêt concerne la proposition de nouvelles formes analytiques de mesure de similarité entre les modèles statistiques et ensuite de les intégrer dans le processus de la méthode WSRC. Un aspect essentiel qui peut être traité serait l'étude de l'invariance à la rotation des images radar pour la problématique de la reconnaissance de cibles. Un autre travail d'intérêt pourrait être de tester les méthodes d'apprentissage profond sur les données radar. Il serait aussi utile d'étudier l'application des méthodes proposées sur d'autres bases de données d'images (optiques, multispectrales, hyperspectrales, ...).

Annexes

ESTIMATION DES PARAMÈTRES STATISTIQUES

A.1 Cas de la modélisation univariée

A.1.1 Distribution Gamma

Dans le travail réalisé et présenté dans ce mémoire, les deux paramètres de la distribution Gamma sont estimés en utilisant la méthode du maximum de vraisemblance (en anglais, ML : *Maximum Likelihood*). Cette méthode est basée sur la fonction de log-vraisemblance qui se calcule comme suit :

$$L(x'; \theta) = \ln \prod_{i=1}^N f(x'_i; \theta) \quad (\text{A.1})$$

avec $x'_1, \dots, x'_N$ est un vecteur de données supposées indépendantes. Si ce vecteur est issu d'une loi Gamma, l'équation (A.1) devient :

$$\begin{aligned} L(x'; b, a) &= \ln \left(\prod_{i=1}^N \frac{a^{-b} x'_i{}^{b-1}}{\Gamma(b)} \exp \left(-\frac{x'_i}{a} \right) \right) \\ &= (b-1) \sum_{i=1}^N \ln(x'_i) - \sum_{i=1}^N \frac{x'_i}{a} - Nb \ln(a) - N \ln(\Gamma(b)) \end{aligned} \quad (\text{A.2})$$

Les deux paramètres b et a sont estimés en maximisant la fonction de l'équation (A.2). Cela est équivalent à annuler ses dérivées par rapport à ses deux paramètres :

$$\frac{\partial L(x'; b, a)}{\partial b} = \sum_{i=1}^N \ln(x'_i) - N \ln(a) - N \Psi(b) = 0 \quad (\text{A.3a})$$

$$\frac{\partial L(x'; b, a)}{\partial a} = \frac{-Nb}{a} + \frac{1}{a^2} \sum_{i=1}^N x'_i = 0 \quad (\text{A.3b})$$

Avec $\Psi(b) = \frac{\Gamma'(b)}{\Gamma(b)}$ est la fonction Digamma [Abramowitz et Stegun, 1965]. À partir de l'équation (A.3b), le paramètre a peut être estimé par :

$$\begin{aligned}\hat{a} &= \frac{1}{bN} \sum_{i=1}^N x'_i \\ &= \frac{\overline{x'}}{b}\end{aligned}\tag{A.4}$$

Avec $\overline{x'}$ désigne la moyenne.

En intégrant la valeur de $\hat{a}$ dans l'équation (A.3a), nous obtenons :

$$\begin{aligned}\frac{\partial L(x'; b, a)}{\partial b} &= \sum_{i=1}^N \ln(x'_i) - N \ln\left(\frac{\overline{x'}}{b}\right) - N\Psi(a) \\ &= \sum_{i=1}^N \ln(x'_i) - N \ln(\overline{x'}) + N \ln(b) - N\Psi(b) \\ &= 0\end{aligned}\tag{A.5}$$

Cela mène à l'équation suivante :

$$\ln(b) - \Psi(b) = \ln(\overline{x'}) - \frac{1}{N} \sum_{i=1}^N \ln(x'_i)\tag{A.6}$$

Dans le travail de [Choi et Wette, 1969], les auteurs proposent de résoudre l'équation (A.6) en se basant sur la méthode de Newton-Raphson tout en initialisant b avec la méthode des moments [Forbes *et al.*, 2011]. L'algorithme A.1 décrit le processus de l'estimation du paramètre de forme b .

A.1.2 Distribution de Weibull

Dans le cas de la distribution de Weibull, ses deux paramètres sont estimés aussi en utilisant la méthode ML [Kwitt et Uhl, 2008]. Si on considère un vecteur de données indépendantes $x'_1, \dots, x'_N$ qui suit la loi de Weibull, alors sa fonction de log-vraisemblance est :

$$\begin{aligned}L(x'; \tau, \mu) &= \ln \left(\prod_{i=1}^N \frac{\tau}{\mu} \left(\frac{x'_i}{\mu} \right)^{\tau-1} \exp \left(- \left(\frac{x'_i}{\mu} \right)^\tau \right) \right) \\ &= N \ln(\tau) - \tau N \ln(\mu) + (\tau - 1) \sum_{i=1}^N \ln(x'_i) - \sum_{i=1}^N \left(\frac{x'_i}{\mu} \right)^\tau\end{aligned}\tag{A.7}$$

Algorithme A.1 Méthode de Newton-Raphson pour l'estimation du paramètre de forme b de la loi Gamma

ENTRÉES: une estimation initiale $\hat{b}_0$ du paramètre b en utilisant la méthode des moments

SORTIES: le paramètre de forme estimé $\hat{b}$

$NiterMax \leftarrow 10$ (le nombre maximal d'itérations)

$\epsilon \leftarrow 10^{-6}$ (la précision de l'algorithme)

$k \leftarrow 0$

Répéter

$$\hat{b}_{k+1} = \hat{b}_k - \frac{g(\hat{b}_k)}{g'(\hat{b}_k)}$$

où

$$g(b) = \ln(b) - \Psi(b) - \ln(\bar{x}') + \frac{1}{N} \sum_{i=1}^N \ln(x'_i)$$

et

$$g'(b) = \frac{1}{b} - \Psi'(b)$$

$k \leftarrow k + 1$

Jusqu'à $|\hat{b}_k - \hat{b}_{k-1}| \leq \epsilon$ ou $|g(\hat{b}_k)| \leq \epsilon$ ou $k = NiterMax$

Retourner $\hat{b}_k$

Afin de maximiser l'équation (A.7), ses dérivées par rapport à τ et μ doivent être nulles [Kwitt et Uhl, 2010] :

$$\frac{\partial L(x'; \tau, \mu)}{\partial \mu} = \frac{-N\tau}{\mu} + \tau \sum_{i=1}^N \frac{x'_i{}^\tau}{\mu^{\tau+1}} = 0 \quad (\text{A.8a})$$

$$\frac{\partial L(x'; \tau, \mu)}{\partial \tau} = \sum_{i=1}^N x'_i{}^\tau \ln(x'_i) - \frac{1}{N} \sum_{i=1}^N x'_i \sum_{i=1}^N (x'_i)^\tau - \frac{1}{\tau} \sum_{i=1}^N (x'_i)^\tau = 0 \quad (\text{A.8b})$$

Pour estimer le paramètre de forme τ , les auteurs dans [Kwitt et Uhl, 2010] contribuent à la résolution de l'équation (A.8b) numériquement via la méthode de Newton-Raphson. Les différentes étapes de cette méthode sont décrites dans l'algorithme A.2.

En se basant sur le paramètre τ estimé et l'équation (A.8a), le paramètre μ peut être déduit à partir de :

$$\hat{\mu} = \left(\frac{1}{N} \sum_{i=1}^N x'_i{}^{\hat{\tau}} \right)^{\frac{1}{\hat{\tau}}} \quad (\text{A.9})$$

Algorithme A.2 Méthode de Newton-Raphson pour l'estimation du paramètre de forme τ de la loi de Weibull

ENTRÉES: une estimation initiale $\hat{\tau}_0$ du paramètre b en utilisant la méthode des moments

SORTIES: le paramètre de forme estimé $\hat{\tau}$

$NiterMax \leftarrow 10$ (le nombre maximal d'itérations)

$\epsilon \leftarrow 10^{-6}$ (la précision de l'algorithme)

$k \leftarrow 0$

Répéter

$$\hat{\tau}_{k+1} = \hat{\tau}_k - \frac{g(\hat{\tau}_k)}{g'(\hat{\tau}_k)}$$

où

$$g(\tau) = \sum_{i=1}^N x'_i{}^\tau \ln(x'_i) - \frac{1}{N} \sum_{i=1}^N x'_i \sum_{i=1}^N (x'_i)^\tau - \frac{1}{\tau} \sum_{i=1}^N (x'_i)^\tau$$

et

$$g'(\tau) = \sum_{i=1}^N x'_i{}^\tau \ln(x'_i)^2 - \frac{1}{N} \sum_{i=1}^N x'_i \sum_{i=1}^N ((x'_i)^\tau \ln(x'_i)) + \frac{1}{\tau^2} \sum_{i=1}^N (x'_i)^\tau - \frac{1}{\tau} \sum_{i=1}^N (x'_i)^\tau \ln(x'_i)$$

$k \leftarrow k + 1$

Jusqu'à $|\hat{\tau}_k - \hat{\tau}_{k-1}| \leq \epsilon$ ou $|g(\hat{\tau}_k)| \leq \epsilon$ ou $k = NiterMax$

Retourner $\hat{\tau}_k$

A.2 Cas de la modélisation multivariée

Pour estimer les hyperparamètres de la copule Gaussienne en utilisant la méthode ML, nous calculons tout d'abord la fonction de vraisemblance comme suit :

$$\begin{aligned} L(\vec{u}; p) &= \ln \left(\prod_{j=1}^N \left(c(F_1(u_{1,j}), \dots, F_d(u_{d,j}); \Sigma) \prod_{i=1}^d f_i(u_i; \theta_i) \right) \right) \\ &= \sum_{j=1}^N \ln c(F_1(u_{1,j}), \dots, F_d(u_{d,j}); \Sigma) + \sum_{j=1}^N \sum_{i=1}^d \ln f_i(u_i; \theta_i) \end{aligned} \quad (\text{A.10})$$

Ainsi, les hyperparamètres sont estimés en maximisant $L(\vec{u}; p)$:

$$\operatorname{argmax} L(\vec{u}; p) \quad (\text{A.11})$$

L'implémentation de cette méthode est complexe, car elle exige d'estimer conjointement les paramètres des distributions marginales (θ_i) et la matrice de covariance (Σ) de la copule Gaussienne. Pour surmonter cette complexité, nous utilisons la méthode IFM (*Inference Functions from Margings*) [Joe, 1997] qui se base sur le principe de la séparation entre les paramètres des lois marginales et les paramètres de la structure de la dépendance de la copule. Elle se résume en deux étapes :

1. Estimation des paramètres des lois marginales θ_i en utilisant l'estimateur ML comme il est décrit dans la sous-section A.1.1 et la sous-section A.1.2.

2. Transformation de chaque échantillon du vecteur multidimensionnel

$U = (u_{1,j}, \dots, u_{d,j})^t, j = 1, \dots, N$ en un vecteur Gaussien $\vec{y}$:

$$\vec{y} = \left(\phi^{-1} \left(F_1(u_{1,j}; \hat{\theta}_1), \dots, F_1(u_{d,j}; \hat{\theta}_1) \right) \right)^t \quad (\text{A.12})$$

Finalement, la matrice de covariance est estimée par :

$$\hat{\Sigma} = \frac{1}{L} \sum_{j=1}^N \vec{y}_j \vec{y}_j^t \quad (\text{A.13})$$

DESCRIPTION DES MÉTHODES DE CLASSIFICATION UTILISÉES LORS DE L'ÉVALUATION DE LA DEUXIÈME MÉTHODE WSRC-KLD PROPOSÉE

B.1 Classifieur KPPV

La méthode des K-Plus Proches Voisins (KPPV) proposée par [Cover et Hart, 1967] est l'une des premières méthodes de classification supervisée. Elle consiste à prédire la classe d'un nouvel individu ve_0 en se basant sur sa distance à un ensemble d'observations connues.

Deux paramètres sont à préciser pour cette méthode de classification :

- Le nombre de voisins : k
- Une métrique de mesure de distance

En se basant sur la base d'apprentissage, les k -plus proches voisins de ve_0 sont sélectionnés. Parmi ces k individus, on identifie la classe C_{k_0} à laquelle appartient le plus grand nombre d'entre eux. Et, c'est à cette classe C_{k_0} que l'individu ve_0 est enfin affecté. Ces étapes sont résumées dans l'algorithme B.1.

Algorithme B.1 Algorithme des k-plus proches voisins

ENTRÉES: IN (ensemble de N individus déjà classifiés), ve_0 (individu à classifier), k (nombre de voisins), une métrique de distance

SORTIES: C_{ve_0} (la classe de ve_0)

Étapes

Recherche des k plus proches individus de ve_0 selon la distance choisie

Retourner C_{ve_0} : la classe à laquelle appartient le plus grand nombre des k individus.

B.2 Classifieur SVM

La méthode SVM (*Support Vector Machines* ou Machines à Vecteurs de Support) est une technique de classification de données qui a été introduite en 1995 par Vapnik [Vapnik, 1995]. Elle tente de séparer linéairement les individus positifs des individus négatifs dans l'ensemble des individus. Les SVM reposent sur deux notions : celle de la marge maximale et celle de la fonction noyau. La marge est la distance entre les individus les plus proches des deux classes. Dans un problème linéairement séparable, les SVM trouvent un

séparateur qui maximise cette marge. Dans le cas d'un problème non linéaire, on utilise une fonction noyau pour projeter les données dans un espace de plus grande dimension où elles seront linéairement séparables, donc deux cas de figure sont distingués : SVM linéaire et SVM non linéaire.

B.2.1 Cas linéairement séparable

Si les données sont linéairement séparables, on parle d'une machine à vecteur de support à marge dure (en anglais, *Hard margin*), dans ce cas il existe de nombreux hyperplans séparateurs qui séparent les exemples positifs (x^+) de ceux négatifs (x^-). L'hyperplan optimal est celui qui maximise la marge entre deux classes (+1 et -1). Cette dernière étant définie comme la distance entre les points les plus proches des deux classes. Ces points particuliers sont appelés vecteurs de support.

L'équation de l'hyperplan est définie comme suit :

$$\varphi(w) = \begin{cases} wx'' + b = 0 & \text{Pour tout } x'' \text{ appartenant à l'hyperplan} \\ wx^+ + b \geq +1 & \text{si } y_i = +1 \\ wx^- + b \leq -1 & \text{si } y_i = -1 \end{cases} \quad (\text{B.1})$$

Ces conditions peuvent être résumées par :

$$y_i(wx_i'' + b) - 1 \geq 0 \quad (\text{B.2})$$

Et la marge M peut s'écrire :

$$M = \frac{w(x^+ - x^-)}{\|w\|} = \frac{2}{\|w\|} \quad (\text{B.3})$$

L'objectif est de chercher l'hyperplan optimal (w et b) qui maximise la marge ($2/\|w\|$), ce qui est équivalent à minimiser $J(w) = \|w\|^2/2$ sous les contraintes de l'équation (B.2) :

$$\begin{cases} \min_n J(w) = \|w\|^2/2 \\ \phi_i(w, b) \leq 0 \end{cases} \quad (\text{B.4})$$

avec $\phi_i(w, b) = 1 - y_i(wve_i + b)$ pour tout $i = 1, \dots, N$. Ce problème d'optimisation peut être résolu en utilisant les multiplicateurs de Lagrange et le dual lagrangien :

$$L_p(w, b, \alpha) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^N \alpha_i [y_i(wve_i + b) - 1] \quad (\text{B.5})$$

où $\alpha_i \geq 0$ sont les multiplicateurs de Lagrange qui peuvent être obtenus sous les conditions de Kuhn, Karush et Tucker (KKT), cela veut dire que l'optimum de la fonction objectif L_p peut être obtenu en la minimisant par rapport à w et b et en la maximisant par rapport

aux α_i :

$$\begin{cases} \frac{\partial L_p}{\partial w_v} = w_v - \sum_{i=1}^N \alpha_i y_i x_i'' = 0 & v = 1, \dots, p \\ \frac{\partial L_p}{\partial b} = - \sum_{i=1}^N \alpha_i y_i = 0 \\ y_i(w \cdot x_i'' + b) - 1 \geq 0 & i = 1, \dots, N \\ \alpha_i \geq 0 & i = 1, \dots, N \\ \alpha_i [y_i(w \cdot x_i'' + b) - 1] = 0 & i = 1, \dots, N \end{cases} \quad (\text{B.6})$$

De l'équation (B.6), on déduit :

$$\begin{cases} w^* = \sum_{i=1}^N \alpha_i^* y_i x_i'' \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases} \quad (\text{B.7})$$

En remplaçant dans l'équation (B.5), on obtient le problème dual donné par l'équation (B.8) qui est à maximiser :

$$\begin{cases} \max_{\alpha} L_p(\alpha) = \sum_{i=1}^N \alpha_i - \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i'' x_j'' \\ \text{Sous contraintes : } \sum_{i=1}^N \alpha_i y_i = 0, \alpha_i \geq 0 \end{cases} \quad (\text{B.8})$$

Ce problème fait partie des problèmes d'optimisation quadratique pour lesquels il existe de nombreux algorithmes de résolution. Le *framework* utilisé dans le travail présenté dans ce mémoire pour manipuler SVM est *libSVM* [Chang et Lin, 2011], dans lequel il est implémenté la méthode *SMO-type decomposition* proposée par [Fan *et al.*, 2015] pour résoudre ce problème.

Les exemples x_i'' ayant des $\alpha_i \neq 0$ représentent les vecteurs de support appartenant aux deux classes. Après la phase d'apprentissage, on garde juste ces vecteurs de support. b peut être calculé à partir de n'importe quel vecteur de support :

$$b = y_i - w x_i'' \quad (\text{B.9})$$

D'un point de vue précision, on prend la moyenne de b pour tous les vecteurs de support :

$$b = \frac{1}{|VS|} \sum_{v e_i \in VS} y_i - w x_i'' \quad (\text{B.10})$$

où VS est l'ensemble des vecteurs de support.

Une fois les paramètres α^* et b^* calculés, la prédiction de la classe d'un nouvel individu x_0'' revient à étudier le signe de :

$$f_{SVM}(x'') = \sum_{x_i'' \in VS} \alpha_i^* y_i x_0'' \cdot v e_i + b^* \quad (\text{B.11})$$

B.2.2 Cas non-linéaire

Dans le cas où les données sont non-linéairement séparables, autrement dit il n'existe pas un hyperplan qui sépare les deux classes, une première solution consiste à admettre une certaine erreur de classification des données. On parle du SVM à marge souple (en anglais, *Soft Margin*).

Le fait d'admettre la mauvaise classification de certains exemples ne peut pas toujours donner une bonne généralisation pour un hyperplan même si ce dernier est optimal. Plutôt qu'une droite, la représentation idéale de la fonction de décision serait celle qui permet de mieux représenter les données d'entraînement. La détermination d'une telle fonction non linéaire est très difficile voire impossible. Pour cela, les données sont amenées dans un espace où cette fonction devient linéaire, cette astuce permet de garder les mêmes modèles de problème d'optimisation vus dans les sections précédentes, utilisant les SVM basés essentiellement sur le principe de séparation linéaire. Cette transformation d'espace est réalisée souvent à l'aide d'une fonction Φ appelée "*Mapping function*" et le nouvel espace est appelé espace de caractéristiques "*Features space*" :

$$\Phi : \mathbb{R}^d \rightarrow E \quad (\text{B.12})$$

qui définit une fonction K appelée noyau (ou *Kernel*) telle que :

$$\begin{aligned} K : \mathbb{R}^p \times \mathbb{R}^p &\rightarrow \mathbb{R} \\ (c, f) &\mapsto \langle \Phi(c), \Phi(f) \rangle \end{aligned} \quad (\text{B.13})$$

Dans ce cas, la fonction de décision devient :

$$f_{SVM}(x_0) = \sum_{x_i \in U} \alpha_i^* y_i K(x_i, x_0) + b^*, \quad (\text{B.14})$$

où VS représente des vecteurs de support bornés.

Les principaux noyaux utilisés dans la littérature sont donnés dans le Tableau B.1.

Noyau	Formule	Paramètres
Linéaire	$K(c, f) = c.f$	—
Polynomial	$K(c, f) = (c.f + 1)^{dd}, dd \in \mathbb{R}$	f
Gaussien	$K(c, f) = e^{-\gamma'' \ c-f\ ^2}, \gamma'' > 0$	γ''
Sigmoïdal	$K(c, f) = \tanh(\gamma'' c.f + rr)$	γ'', rr

TABLE B.1 – Noyaux du SVM.

B.2.3 Classification multi-classe

Les SVM ont été initialement développés pour traiter des problèmes binaires mais ils peuvent être adaptés pour traiter les problèmes multi-classes. Nous décrivons ici deux approches qui se basent sur la décomposition du problème multi-classe en plusieurs hyperplans binaires.

un-contre-reste C'est la méthode la plus simple et la plus ancienne, elle consiste à déterminer pour chaque classe k'' un hyperplan $H_{k''}(w_{k''}; b_{k''})$ le séparant de toutes les autres classes tout en déterminant une fonction de décision f_{SVM} . Cette classe k'' est considérée comme étant la classe positive (+1) et les autres classes comme étant la classe négative (-1), ce qui résulte, pour un problème à K'' classes, en K'' SVM binaires.

L'affectation d'un nouvel individu x_0'' à une classe C_{ii} se fait en général par la relation :

$$ii = \arg \max_{ii=1 \dots Nc} f_{SVM_{ii}}(x_0'') \quad (B.15)$$

Parmi les problèmes de cette méthode, on note que quelques individus peuvent ne pas être classifiés à cause de la naissance de plusieurs zones d'indécision. D'autre part, l'aspect asymétrique de cette méthode est critiqué puisque chaque hyperplan est entraîné sur un nombre d'exemples négatifs beaucoup plus important que le nombre d'exemples positifs.

un-contre-un Cette méthode, appelée aussi "*pairwise*", consiste à utiliser un classifieur pour chaque paire de classes. Au lieu d'apprendre K'' fonctions de décisions, on discrimine chaque classe de chaque autre classe, ainsi $K''(K'' - 1)/2$ fonctions de décisions sont apprises.

Pour chaque paire de classes, la méthode définit une fonction de décision binaire. Si on veut classifier un nouvel individu, chaque classe effectue un vote, la classe majoritaire après vote sera celle à qui le point est affecté. Nous notons que la méthode implémentée dans le *framework libsvm* [Chang et Lin, 2011] est l'approche un-contre-un.

Les travaux réalisés et présentés dans ce mémoire ont été valorisés dans les publications indiquées ci-dessous :

Revues internationales (2)

1. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Radar Target Recognition via Salient Keypoint Descriptors and Multitask Sparse Representation", Remote Sensing (**IF=3.244**), vol. 10, no. 843, May 2018.
2. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Target Recognition in Radar Images using Weighted Statistical Dictionary-Based Sparse Representation", IEEE Geoscience and Remote Sensing Letters (**IF=2.761**), vol. 14, no. 12, 2403-2407, December 2017.

Papier soumis

- **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Copula Joint Statistical Model and Weighted Sparse Representation based Classification for Radar Target Recognition", Soumis à IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (J-STARS).

Conférences nationales et internationales (9)

3. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Aircraft Target Recognition using Copula Joint Statistical Model and Sparse Representation Based Classification", IEEE Geoscience and Remote Sensing Symposium (IGARSS), Valencia-Spain, 23-27 July 2018.
4. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Target Recognition in ISAR Images based on Relative Phases of Complex Wavelet Coefficients and Sparse Classification", 4th IEEE International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), Sousse-Tunisie, 21-24 March 2018.
5. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Saliency Attention and SIFT Keypoints Combination for Automatic Target Recognition on MSTAR dataset", 3th IEEE International Conference on Advanced Technologies for Signal

- and Image Processing (ATSIP), Fez-Maroc, 22-24 May 2017.
6. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Classification parcimonieuse pour l'aide à la reconnaissance de cibles radar", 17 ème édition de la conférence Extraction et Gestion de Connaissance (EGC), Grenoble-France, 23-27 Janvier 2017.
 7. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Filtrage attentionnel des points caractéristiques SIFT pour la reconnaissance de cibles radar", 1 ère édition des journées SIGnal, image, Multimédia et Applications (SIGMA), Fès-Maroc, 21-22 Décembre 2016.
 8. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "A non-Gaussian statistical modeling of SIFT and DT-CWT for radar target recognition", 13th IEEE International Conference on Computer Systems and Applications (AICCSA), Agadir-Maroc, 29 November - 02 December 2016.
 9. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Aircraft recognition using a statistical model and sparse representation", First ACM International Conference on Big Data and Advanced Wireless technologies (BDaw), Bulgarie, 10-11 November 2016.
 10. **A. Karine**, A. Toumi, A. Khenchaf, M. EL Hassouni, "Visual salient SIFT keypoints descriptors for automatic target recognition", 6th IEEE European Workshop on Visual Information Processing (EUVIP), Marseille-France, 25-27 October 2016.
 11. **A. Karine**, A. Toumi, M. EL Hassouni, A. Khenchaf, "Modélisation et réalisation d'un système de détection de cibles radar", Journée URAC-Maroc, Rabat, 28 Novembre 2015.



BIBLIOGRAPHIE

- [Abramowitz et Stegun, 1965] ABRAMOWITZ, M. et STEGUN, I. A. (1965). *Handbook of mathematical functions with formulas, graphs, and mathematical table*, volume 2172. Dover New York.
- [Agrawal et al., 2015] AGRAWAL, A., MANGALRAJ, P. et BISHERWAL, M. A. (2015). Target detection in SAR images using sift. In *Signal Processing and Information Technology (ISSPIT), 2015 IEEE International Symposium on*, pages 90–94.
- [Aharon et al., 2006] AHARON, M., ELAD, M., BRUCKSTEIN, A. et al. (2006). K-SVD : An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Transactions on signal processing*, 54(11):4311.
- [Amoon et Rezai-Rad, 2013] AMOON, M. et REZAI-RAD, G.-A. (2013). Automatic target recognition of synthetic aperture radar (SAR) images based on optimal selection of zernike moments features. *IET Computer Vision*, 8(2):77–85.
- [Anagnostopoulos, 2009] ANAGNOSTOPOULOS, G. C. (2009). SVM-based target recognition from synthetic aperture radar images using target region outline descriptors. *Nonlinear Analysis : Theory, Methods & Applications*, 71(12):e2934–e2939.
- [Bachofer et al., 2016] BACHOFER, F., QUÉNÉHERVÉ, G., ZWIENER, T., MAERKER, M. et HOCHSCHILD, V. (2016). Comparative analysis of edge detection techniques for SAR images. *European Journal of Remote Sensing*, 49(1):205–224.
- [Baraniuk, 2007] BARANIUK, R. G. (2007). Compressive sensing. *IEEE signal processing magazine*, 24(4):118–121.
- [Baraniuk et al., 2010] BARANIUK, R. G., CEVHER, V., DUARTE, M. F. et HEGDE, C. (2010). Model-based compressive sensing. *IEEE Transactions on Information Theory*, 56(4):1982–2001.
- [Belkhaoui, 2014] BELKHAOUI, B. (2014). Analyse et traitement des images radar pour l’aide à la reconnaissance de cibles aériennes.
- [Belkhaoui et al., 2013] BELKHAOUI, B., TOUMI, A., KHALFALLAH, A., KHENCHAF, A. et BOUHLEL, M. (2013). Fusion fourier descriptors from the EM, k-means and fisher algorithms for radar target recognition. *International Journal of Computer and Information Technology*, 2(04).

- [Bennani, 2012] BENNANI, Y. (2012). *Signature électromagnétique bistatique d'une cible complexe intégrée dans son environnement : Application à l'imagerie ISAR d'une scène maritime*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Benzécri *et al.*, 1973] BENZÉCRI, J.-P. *et al.* (1973). *L'analyse des données*, volume 2. Dunod Paris.
- [Blanchard, 2006] BLANCHARD, Y. (2006). Le centenaire de l'invention du radar par christian hülsmeier, retour sur un anniversaire. *REE. Revue de l'électricité et de l'électronique*, (2):87–92.
- [Bofill et Zibulevsky, 2001] BOFILL, P. et ZIBULEVSKY, M. (2001). Underdetermined blind source separation using sparse representations. *Signal processing*, 81(11):2353–2362.
- [Bolourchi *et al.*, 2017] BOLOURCHI, P., DEMIREL, H. et UYSAL, S. (2017). Target recognition in SAR images using radial chebyshev moments. *Signal, Image and Video Processing*, 11(6):1033–1040.
- [Borji et Itti, 2013] BORJI, A. et ITTI, L. (2013). State-of-the-art in visual attention modeling. *IEEE transactions on pattern analysis and machine intelligence*, 35(1):185–207.
- [Brandwood, 1983] BRANDWOOD, D. (1983). A complex gradient operator and its application in adaptive array theory. In *IEE Proceedings F-Communications, Radar and Signal Processing*, volume 130, pages 11–16.
- [Bryant et Garber, 1999] BRYANT, M. L. et GARBER, F. D. (1999). SVM classifier applied to the mstar public data set. In *Algorithms for Synthetic Aperture Radar Imagery VI*, volume 3721, pages 355–361. International Society for Optics and Photonics.
- [Candes et Romberg, 2005] CANDÉS, E. et ROMBERG, J. (2005). 11-magic : Recovery of sparse signals via convex programming. *URL* : www.acm.caltech.edu/l1magic/downloads/l1magic.pdf, 4:14.
- [Celik et Ma, 2010] CELIK, T. et MA, K.-K. (2010). Unsupervised change detection for satellite images using dual-tree complex wavelet transform. *IEEE Transactions on Geoscience and Remote Sensing*, 48(3):1199–1210.
- [Celik et Tjahjadi, 2009] CELIK, T. et TJAHJADI, T. (2009). Multiscale texture classification using dual-tree complex wavelet transform. *Pattern Recognition Letters*, 30(3):331–339.
- [Chang et Lin, 2011] CHANG, C.-C. et LIN, C.-J. (2011). Libsvm : a library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3):27.
- [Chang et You, 2018] CHANG, M. et YOU, X. (2018). Target recognition in SAR images based on information-decoupled representation. *Remote Sensing*, 10(1):138.
- [Chang et Li, 1994] CHANG, Y.-L. et LI, X. (1994). Adaptive image region-growing. *IEEE transactions on image processing*, 3(6):868–872.

- [Chen et Wang, 2014a] CHEN, S. et WANG, H. (2014a). SAR target recognition based on deep learning. In *Data Science and Advanced Analytics (DSAA), 2014 International Conference on*, pages 541–547. IEEE.
- [Chen et Wang, 2014b] CHEN, S. et WANG, H. (2014b). SAR target recognition based on deep learning. In *2014 International Conference on Data Science and Advanced Analytics (DSAA)*, pages 541–547.
- [Chen et al., 2016] CHEN, S., WANG, H., XU, F. et JIN, Y. Q. (2016). Target classification using the deep convolutional networks for SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8):4806–4817.
- [Chen et al., 2001] CHEN, S. S., DONOHO, D. L. et SAUNDERS, M. A. (2001). Atomic decomposition by basis pursuit. *SIAM review*, 43(1):129–159.
- [Chen et al., 2011] CHEN, Y., NASRABADI, N. M. et TRAN, T. D. (2011). Hyperspectral image classification using dictionary-based sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10):3973–3985.
- [Cho et al., 2017] CHO, H.-W., CHO, Y.-R., SONG, W.-J. et KIM, B.-K. (2017). Image matting for automatic target recognition. *IEEE Transactions on Aerospace and Electronic Systems*, 53(5):2233–2250.
- [Choi et Wette, 1969] CHOI, S. C. et WETTE, R. (1969). Maximum likelihood estimation of the parameters of the gamma distribution and their bias. *Technometrics*, 11(4):683–690.
- [Combettes et Wajs, 2005] COMBETTES, P. L. et WAJS, V. R. (2005). Signal recovery by proximal forward-backward splitting. *Multiscale Modeling & Simulation*, 4(4):1168–1200.
- [Comblet, 2005] COMBLET, F. (2005). *Détection, localisation et identification de cibles radar par imagerie électromagnétique bistatique*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Congalton, 1991] CONGALTON, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1):35 – 46.
- [Cooley et al., 2017] COOLEY, C., COLEMAN, S., GARDINER, B. et BRYAN, S. (2017). Saliency detection and object classification. *Irish Machine Vision and Image Processing Conference*.
- [Cover et Hart, 1967] COVER, T. et HART, P. (1967). Nearest neighbor pattern classification. *Information Theory, IEEE Transactions on*, 13(1):21–27.
- [Cumming et Wong, 2005] CUMMING, I. G. et WONG, F. H. (2005). Digital processing of synthetic aperture radar data. *Artech house*, 1(2):3.
- [Dai et Milenkovic, 2009] DAI, W. et MILENKOVIC, O. (2009). Subspace pursuit for compressive sensing signal reconstruction. *IEEE transactions on Information Theory*, 55(5):2230–2249.

- [Dellinger *et al.*, 2015] DELLINGER, F., DELON, J., GOUSSEAU, Y., MICHEL, J. et TUPIN, F. (2015). SAR-sift : a sift-like algorithm for SAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 53(1):453–466.
- [Demartines et Hérault, 1997] DEMARTINES, P. et HÉRAULT, J. (1997). Curvilinear component analysis : A self-organizing neural network for nonlinear mapping of data sets. *IEEE Transactions on neural networks*, 8(1):148–154.
- [Deriche, 1987] DERICHE, R. (1987). Using canny’s criteria to derive a recursively implemented optimal edge detector. *International journal of computer vision*, 1(2):167–187.
- [Diao *et al.*, 2016] DIAO, W., SUN, X., ZHENG, X., DOU, F., WANG, H. et FU, K. (2016). Efficient saliency-based object detection in remote sensing images using deep belief networks. *IEEE Geoscience and Remote Sensing Letters*, 13(2):137–141.
- [Ding *et al.*, 2016] DING, J., CHEN, B., LIU, H. et HUANG, M. (2016). Convolutional neural network with data augmentation for SAR target recognition. *IEEE Geoscience and remote sensing letters*, 13(3):364–368.
- [Do et Vetterli, 2002] DO, M. N. et VETTERLI, M. (2002). Wavelet-based texture retrieval using generalized gaussian density and Kullback-Leibler distance. *IEEE transactions on image processing*, 11(2):146–158.
- [Do et Vetterli, 2005] DO, M. N. et VETTERLI, M. (2005). The contourlet transform : an efficient directional multiresolution image representation. *IEEE Transactions on image processing*, 14(12):2091–2106.
- [Dong et Kuang, 2015a] DONG, G. et KUANG, G. (2015a). Classification on the monogenic scale space : application to target recognition in SAR image. *IEEE Transactions on Image Processing*, 24(8):2527–2539.
- [Dong et Kuang, 2015b] DONG, G. et KUANG, G. (2015b). Target recognition via information aggregation through dempster-shafer’s evidence theory. *IEEE Geoscience and Remote Sensing Letters*, 12(6):1247–1251.
- [Dong et Kuang, 2016a] DONG, G. et KUANG, G. (2016a). SAR target recognition via sparse representation of monogenic signal on grassmann manifolds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(3):1308–1319.
- [Dong et Kuang, 2016b] DONG, G. et KUANG, G. (2016b). A soft decision rule for sparse signal modeling via dempster-shafer evidential reasoning. *IEEE Geoscience and Remote Sensing Letters*, 13(10):1567–1571.
- [Dong *et al.*, 2015] DONG, G., KUANG, G., WANG, N., ZHAO, L. et LU, J. (2015). SAR target recognition via joint sparse representation of monogenic signal. *IEEE Journal of selected topics in applied earth observations and remote sensing*, 8(7):3316–3328.
- [Dong *et al.*, 2014a] DONG, G., KUANG, G., ZHAO, L., LU, J. et LU, M. (2014a). Joint sparse representation of monogenic components : With application to automatic target recognition in SAR imagery. In *Geoscience and Remote Sensing Symposium (IGARSS), 2014 IEEE International*, pages 549–552. IEEE.

- [Dong *et al.*, 2012] DONG, G., WANG, N., HU, C. et JIANG, Y. (2012). SAR image segmentation combining the pm diffusion model and MRF model. *In International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 4307–4310. IEEE.
- [Dong *et al.*, 2014b] DONG, G., WANG, N. et KUANG, G. (2014b). Sparse representation of monogenic signal : With application to target recognition in SAR images. *IEEE Signal Processing Letters*, 21(8):952–956.
- [Donoho et Huo, 2001] DONOHO, D. L. et HUO, X. (2001). Uncertainty principles and ideal atomic decomposition. *IEEE transactions on information theory*, 47(7):2845–2862.
- [Donoho *et al.*, 2012] DONOHO, D. L., TSAIG, Y., DRORI, I. et STARCK, J.-L. (2012). Sparse solution of underdetermined systems of linear equations by stagewise orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 58(2):1094–1121.
- [Donoho *et al.*, 1998] DONOHO, D. L., VETTERLI, M., DEVORE, R. A. et DAUBECHIES, I. (1998). Data compression and harmonic analysis. *IEEE Transactions on Information Theory*, 44(6):2435–2476.
- [Doo, 2016] DOO, S. H. (2016). *Analysis, Modeling & Exploitation of Variability in Radar Images*. Thèse de doctorat, The Ohio State University.
- [Du *et al.*, 2016] DU, K., DENG, Y., WANG, R., ZHAO, T. et LI, N. (2016). SAR atr based on displacement-and rotation-insensitive cnn. *Remote Sensing Letters*, 7(9):895–904.
- [Dubois et Prade, 1988] DUBOIS, D. et PRADE, H. (1988). Representation and combination of uncertainty with belief functions and possibility measures. *Computational intelligence*, 4(3):244–264.
- [Dubois et Prade, 1998] DUBOIS, D. et PRADE, H. (1998). Possibility theory : qualitative and quantitative aspects. *In Quantified representation of uncertainty and imprecision*, pages 169–226. Springer.
- [El-Darymli, 2015] EL-DARYMLI, K. (2015). *Holism for target recognition in synthetic aperture radar imagery*. Thèse de doctorat, Memorial University of Newfoundland.
- [El-Darymli *et al.*, 2016] EL-DARYMLI, K., GILL, E. W., MCGUIRE, P., POWER, D. et MOLONEY, C. (2016). Automatic target recognition in synthetic aperture radar imagery : A state-of-the-art review. *IEEE Access*, 4:6014–6058.
- [Engan *et al.*, 1999] ENGAN, K., AASE, S. O. et HUSOY, J. H. (1999). Method of optimal directions for frame design. *In Acoustics, Speech, and Signal Processing, 1999. Proceedings., 1999 IEEE International Conference on*, volume 5, pages 2443–2446. IEEE.
- [Fan *et al.*, 2015] FAN, Z., NI, M., ZHU, Q. et LIU, E. (2015). Weighted sparse representation for face recognition. *Neurocomputing*, 151(1):304–309.
- [Fei-Fei et Perona, 2005] FEI-FEI, L. et PERONA, P. (2005). A bayesian hierarchical model for learning natural scene categories. *In Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 2, pages 524–531.

- [Felsberg et Sommer, 2001] FELSBERG, M. et SOMMER, G. (2001). The monogenic signal. *IEEE Transactions on Signal Processing*, 49(12):3136–3144.
- [Feng *et al.*, 2010] FENG, S., XU, D. et YANG, X. (2010). Attention-driven salient edge(s) and region(s) extraction with application to CBIR. *Signal Processing*, 90(1):1–15.
- [Fisher et Switzer, 1985] FISHER, N. et SWITZER, P. (1985). Chi-plots for assessing dependence. *Biometrika*, 72(2):253–265.
- [Fisher et Switzer, 2001] FISHER, N. et SWITZER, P. (2001). Graphical assessment of dependence : Is a picture worth 100 tests ? *The American Statistician*, 55(3):233–239.
- [Flusser, 2000] FLUSSER, J. (2000). On the independence of rotation moment invariants. *Pattern recognition*, 33(9):1405–1410.
- [Forbes *et al.*, 2011] FORBES, C., EVANS, M., HASTINGS, N. et PEACOCK, B. (2011). *Statistical distributions*. John Wiley & Sons.
- [Frintrop, 2011] FRINTROP, S. (2011). Towards attentive robots. *Paladyn, Journal of Behavioral Robotics*, 2(2):64–70.
- [Gao *et al.*, 2017a] GAO, F., HUANG, T., WANG, J., SUN, J., YANG, E. et HUSSAIN, A. (2017a). Combining deep convolutional neural network and SVM to SAR image target recognition. In *2017 IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCoM) and IEEE Smart Data (SmartData)*, pages 1082–1085.
- [Gao *et al.*, 2017b] GAO, F., YOU, J., WANG, J., SUN, J., YANG, E. et ZHOU, H. (2017b). A novel target detection method for SAR images based on shadow proposal and saliency analysis. *Neurocomputing*, 267:220–231.
- [Gomes *et al.*, 2008] GOMES, J. P. P., BRANCALION, J. F. B. et FERNANDES, D. (2008). Automatic target recognition in synthetic aperture radar image using multiresolution analysis and classifiers combination. In *Radar Conference, 2008. RADAR'08. IEEE*, pages 1–5. IEEE.
- [Gonzalez et Woods, 2012] GONZALEZ, R. C. et WOODS, R. E. (2012). Digital image processing.
- [Hair *et al.*, 1998] HAIR, J. F., BLACK, W. C., BABIN, B. J., ANDERSON, R. E., TATHAM, R. L. *et al.* (1998). *Multivariate data analysis*, volume 5. Prentice hall Upper Saddle River, NJ.
- [Hartigan, 2012] HARTIGAN, J. A. (2012). *Bayes theory*. Springer Science & Business Media.
- [Hartigan et Wong, 1979] HARTIGAN, J. A. et WONG, M. A. (1979). Algorithm as 136 : A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1):100–108.

- [Hill *et al.*, 2014] HILL, P. R., ACHIM, A., BULL, D. R. et AL-MUALLA, M. E. (2014). Dual-tree complex wavelet coefficient magnitude modelling using the bivariate cauchy-rayleigh distribution for image denoising. *Signal Processing*, 105:464–472.
- [Hoover *et al.*, 1996] HOOVER, A., JEAN-BAPTISTE, G., JIANG, X., FLYNN, P. J., BUNKE, H., GOLDFOF, D. B., BOWYER, K., EGGERT, D. W., FITZGIBBON, A. et FISHER, R. B. (1996). An experimental comparison of range image segmentation algorithms. *IEEE transactions on pattern analysis and machine intelligence*, 18(7):673–689.
- [Housseini *et al.*, 2017] HOUSSEINI, A. E., TOUMI, A. et KHENCHAF, A. (2017). Deep learning for target recognition from SAR images. In *2017 Seminar on Detection Systems Architectures and Technologies (DAT)*, pages 1–5.
- [Huang et Qiu, 2018] HUANG, P. et QIU, W. (2018). A robust decision fusion strategy for SAR target recognition. *Remote Sensing Letters*, 9(6):507–514.
- [Hudson et Psaltis, 1993] HUDSON, S. et PSALTIS, D. (1993). Correlation filters for aircraft identification from radar range profiles. *IEEE Transactions on Aerospace and Electronic systems*, 29(3):741–748.
- [Iqbal *et al.*, 2013] IQBAL, M. Z., GHAFOOR, A. et SIDDIQUI, A. M. (2013). Satellite image resolution enhancement using dual-tree complex wavelet transform and nonlocal means. *IEEE geoscience and remote sensing letters*, 10(3):451–455.
- [Itti *et al.*, 1998] ITTI, L., KOCH, C. et NIEBUR, E. (1998). A model of saliency-based visual attention for rapid scene analysis. *IEEE Transactions on pattern analysis and machine intelligence*, 20(11):1254–1259.
- [Jacobs et O’Sullivan, 2000] JACOBS, S. P. et O’SULLIVAN, J. A. (2000). Automatic target recognition using sequences of high resolution radar range-profiles. *IEEE Transactions on Aerospace and Electronic Systems*, 36(2):364–381.
- [Jakowatz *et al.*, 2012] JAKOWATZ, C. V., WAHL, D. E., EICHEL, P. H., GHIGLIA, D. C. et THOMPSON, P. A. (2012). *Spotlight-Mode Synthetic Aperture Radar : A Signal Processing Approach*. Springer Science & Business Media.
- [Jdey, 2014] JDEY, I. (2014). *Contribution des techniques de fusion et de classification des images pour l’aide à la reconnaissance des cibles non coopératives*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Jdey *et al.*, 2012a] JDEY, I., TOUMI, A., DHIBI, M. et KHENCHAF, A. (2012a). The contribution of fusion techniques in the recognition systems of radar targets. *Radar 2012, Oct 2012, United Kingdom*.
- [Jdey *et al.*, 2012b] JDEY, I., TOUMI, A., KHENCHAF, A., DHIBI, M. et BOUHLEL, M. (2012b). Fuzzy fusion system for radar target recognition. *International Journal of Computer Applications & Information Technology*, 1(3):136–142.
- [Joe, 1997] JOE, H. (1997). *Multivariate models and multivariate dependence concepts*. CRC Press.

- [Joyce, 2011] JOYCE, J. M. (2011). Kullback-leibler divergence. *In International Encyclopedia of Statistical Science*, pages 720–722. Springer.
- [Kang et al., 2017] KANG, M., JI, K., LENG, X., XING, X. et ZOU, H. (2017). Synthetic aperture radar target recognition with feature fusion based on a stacked autoencoder. *Sensors*, 17(1):192.
- [Kanopoulos et al., 1988] KANOPOULOS, N., VASANTHAVADA, N. et BAKER, R. L. (1988). Design of an image edge detection filter using the sobel operator. *IEEE Journal of solid-state circuits*, 23(2):358–367.
- [Kay, 1988] KAY, S. M. (1988). *Modern spectral estimation*. Pearson Education India.
- [Kennel et al., 2017] KENNEL, P., FIORIO, C. et BORNE, F. (2017). Supervised image segmentation using q-shift dual-tree complex wavelet transform coefficients with a texton approach. *Pattern Analysis and Applications*, 20(1):227–237.
- [Keydel et al., 1996] KEYDEL, E. R., LEE, S. W. et MOORE, J. T. (1996). MSTAR extended operating conditions : A tutorial. *In Algorithms for Synthetic Aperture Radar Imagery III*, volume 2757, pages 228–243. International Society for Optics and Photonics.
- [Khadra, 2012] KHADRA, S. B. (2012). *Etude de la signature EM bistatique d’une surface maritime hétérogène avec prise en compte des phénomènes hydrodynamiques*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Kim et al., 2005] KIM, K.-T., SEO, D.-K. et KIM, H.-T. (2005). Efficient classification of ISAR images. *IEEE Transactions on Antennas and Propagation*, 53(5):1611–1621.
- [Kingsbury, 1999] KINGSBURY, N. (1999). Image processing with complex wavelets. *Philosophical Transactions of the Royal Society of London A : Mathematical, Physical and Engineering Sciences*, 357(1760):2543–2560.
- [Kingsbury, 2001] KINGSBURY, N. (2001). Complex wavelets for shift invariant analysis and filtering of signals. *Applied and computational harmonic analysis*, 10(3):234–253.
- [Kingsbury, 1998] KINGSBURY, N. G. (1998). The dual-tree complex wavelet transform : a new technique for shift invariance and directional filters. *In Proc. 8th IEEE DSP workshop*, volume 8, page 86. Utah.
- [Knee et al., 2011] KNEE, P., THIAGARAJAN, J. J., RAMAMURTHY, K. N. et SPANIAS, A. (2011). SAR target classification using sparse representations and spatial pyramids. *In Radar Conference (RADAR), 2011 IEEE*, pages 294–298. IEEE.
- [Koch et Ullman, 1987] KOCH, C. et ULLMAN, S. (1987). Shifts in selective visual attention : towards the underlying neural circuitry. *In Matters of intelligence*, pages 115–141. Springer.
- [Krim et Viberg, 1996] KRIM, H. et VIBERG, M. (1996). Two decades of array signal processing research : the parametric approach. *IEEE signal processing magazine*, 13(4): 67–94.

- [Krishnamoorthy, 2006] KRISHNAMOORTHY, K. (2006). *Handbook of statistical distributions with applications*. Chapman and Hall/CRC.
- [Krizhevsky et al., 2012] KRIZHEVSKY, A., SUTSKEVER, I. et HINTON, G. E. (2012). Imagenet classification with deep convolutional neural networks. *In Advances in neural information processing systems*, pages 1097–1105.
- [Kumar, 2017] KUMAR, N. (2017). Thresholding in salient object detection : a survey. *Multimedia Tools and Applications*, pages 1–32.
- [Kwitt, 2010] KWITT, R. (2010). *Statistical modeling in the wavelet domain and applications*. Thèse de doctorat, University of Salzburg, Salzburg, Austria.
- [Kwitt et al., 2011] KWITT, R., MEERWALD, P. et UHL, A. (2011). Efficient texture image retrieval using copulas in a bayesian framework. *IEEE transactions on image processing*, 20(7):2063–2077.
- [Kwitt et Uhl, 2008] KWITT, R. et UHL, A. (2008). Image similarity measurement by Kullback-Leibler divergences between complex wavelet subband statistics for texture retrieval. *In 15th IEEE International Conference on Image Processing*, pages 933–936. IEEE.
- [Kwitt et Uhl, 2010] KWITT, R. et UHL, A. (2010). Lightweight probabilistic texture retrieval. *IEEE Transactions on Image Processing*, 19(1):241–253.
- [Laanaya, 2007] LAANAYA, H. (2007). *Classification en environnement incertain : application à la caractérisation de sédiments marins*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Lacomme, 2001] LACOMME, P. (2001). *Air and spaceborne radar systems : An introduction*, volume 11. William Andrew.
- [Ladoux et al., 2009] LADOUX, P.-O., ROSENBERGER, C. et DORIZZI, B. (2009). Palm vein verification system based on sift matching. *In International Conference on Biometrics*, pages 1290–1298. Springer.
- [Larson, 1931] LARSON, S. C. (1931). The shrinkage of the coefficient of multiple correlation. *Journal of Educational Psychology*, 22(1):45.
- [Lasmar, 2012] LASMAR, N.-E. (2012). *Modélisation stochastique pour l’analyse d’images texturées : Approches Bayésiennes pour la caractérisation dans le domaine des transformées*. Thèse de doctorat, Université Sciences et Technologies-Bordeaux I.
- [Lasmar et Berthoumieu, 2014] LASMAR, N.-E. et BERTHOUMIEU, Y. (2014). Gaussian copula multivariate modeling for texture image retrieval using wavelet transforms. *IEEE Transactions on Image Processing*, 23(5):2246–2261.
- [LeCun et al., 2015] LECUN, Y., BENGIO, Y. et HINTON, G. (2015). Deep learning. *nature*, 521(7553):436.
- [Lewis et al., 2007] LEWIS, J. J., O’CALLAGHAN, R. J., NIKOLOV, S. G., BULL, D. R. et CANAGARAJAH, N. (2007). Pixel-and region-based image fusion with complex wavelets. *Information fusion*, 8(2):119–130.

- [Li *et al.*, 2017a] LI, C., BAO, W., XU, L. et ZHANG, H. (2017a). Clustered multi-task learning for automatic radar target recognition. *Sensors*, 17(10):2218.
- [Li *et al.*, 2017b] LI, C., HUANG, Y. et ZHU, L. (2017b). Color texture image retrieval based on gaussian copula models of gabor wavelets. *Pattern Recognition*, 64:118–129.
- [Li et Du, 2016] LI, W. et DU, Q. (2016). A survey on representation-based classification and detection in hyperspectral remote sensing imagery. *Pattern Recognition Letters*, 83:115 – 123. *Advances in Pattern Recognition in Remote Sensing*.
- [Liao *et al.*, 2013] LIAO, S., JAIN, A. K. et LI, S. Z. (2013). Partial face recognition : Alignment-free approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(5):1193–1205.
- [Lin *et al.*, 2017] LIN, Z., JI, K., KANG, M., LENG, X. et ZOU, H. (2017). Deep convolutional highway unit network for SAR target classification with limited labeled training data. *IEEE Geoscience and Remote Sensing Letters*, 14(7):1091–1095.
- [Liu et Li, 2013] LIU, H. et LI, S. (2013). Decision fusion of sparse representation and support vector machine for SAR image target recognition. *Neurocomputing*, 113:97–104.
- [Liu *et al.*, 2014] LIU, M., WU, Y., ZHAO, W., ZHANG, Q., LI, M. et LIAO, G. (2014). Dempster-shafer fusion of multiple sparse representation and statistical property for SAR target configuration recognition. *IEEE Geoscience and Remote Sensing Letters*, 11(6):1106–1110.
- [Lo *et al.*, 2011] LO, E. H., PICKERING, M. R., FRATER, M. R. et ARNOLD, J. F. (2011). Image segmentation from scale and rotation invariant texture features from the double dyadic dual-tree complex wavelet transform. *Image and Vision Computing*, 29(1):15–28.
- [Lowe, 2004a] LOWE, D. (2004a). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2):91–110.
- [Lowe, 1999] LOWE, D. G. (1999). Object recognition from local scale-invariant features. *In The proceedings of the seventh international conference on Computer vision*, volume 2, pages 1150–1157. Ieee.
- [Lowe, 2004b] LOWE, D. G. (2004b). Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2):91–110.
- [Lu *et al.*, 2013] LU, C., MIN, H., GUI, J., ZHU, L. et LEI, Y. (2013). Face recognition via weighted sparse representation. *Journal of Visual Communication and Image Representation*, 24(2):111–116.
- [Mallat et Zhang, 1993] MALLAT, S. et ZHANG, Z. (1993). Matching pursuit with time-frequency dictionaries. Rapport technique, Courant Institute of Mathematical Sciences New York United States.
- [Mamdani, 1974] MAMDANI, E. H. (1974). Application of fuzzy algorithms for control of simple dynamic plant. *In Proceedings of the institution of electrical engineers*, volume 121, pages 1585–1588. IET.

- [Mangai *et al.*, 2010] MANGAI, U. G., SAMANTA, S., DAS, S. et CHOWDHURY, P. R. (2010). A survey of decision fusion and feature fusion strategies for pattern classification. *IETE Technical review*, 27(4):293–307.
- [Massey Jr, 1951] MASSEY JR, F. J. (1951). The kolmogorov-smirnov test for goodness of fit. *Journal of the American statistical Association*, 46(253):68–78.
- [McCandless et Jackson, 2004] MCCANDLESS, S. et JACKSON, C. (2004). Chapter 1 : Principles of synthetic aperture radar, 2004. *Note : The Synthetic Aperture Radar Marine User's Manual*, page 8.
- [McCulloch et Pitts, 1943] MCCULLOCH, W. S. et PITTS, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133.
- [Mercier *et al.*, 2008] MERCIER, G., MOSER, G. et SERPICO, S. B. (2008). Conditional copulas for change detection in heterogeneous remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5):1428–1441.
- [Mikolajczyk et Schmid, 2001] MIKOLAJCZYK, K. et SCHMID, C. (2001). Indexing based on scale invariant interest points. In *Eighth IEEE International Conference on Computer Vision*, volume 1, pages 525–531. IEEE.
- [Mikolajczyk et Schmid, 2004] MIKOLAJCZYK, K. et SCHMID, C. (2004). Scale & affine invariant interest point detectors. *International journal of computer vision*, 60(1):63–86.
- [Mishra et Motaung, 2015] MISHRA, A. K. et MOTAUNG, T. (2015). Application of linear and nonlinear PCA to SAR ATR. In *Radioelektronika (RADIOELEKTRONIKA), 2015 25th International Conference*, pages 349–354. IEEE.
- [Moon, 1996] MOON, T. K. (1996). The expectation-maximization algorithm. *IEEE Signal processing magazine*, 13(6):47–60.
- [Morgan, 2015] MORGAN, D. A. (2015). Deep convolutional neural networks for ATR from SAR imagery. In *Algorithms for Synthetic Aperture Radar Imagery XXII*, volume 9475, page 94750F. International Society for Optics and Photonics.
- [Nakayama et Mackeben, 1989] NAKAYAMA, K. et MACKEBEN, M. (1989). Sustained and transient components of focal visual attention. *Vision research*, 29(11):1631–1647.
- [Negrel *et al.*, 2014] NEGREL, R., PICARD, D. et GOSSELIN, P.-H. (2014). Dimensionality reduction of visual features using sparse projectors for content-based image retrieval. In *IEEE International Conference on Image Processing (ICIP)*, pages 2192–2196. IEEE.
- [Olshausen et Field, 1997] OLSHAUSEN, B. A. et FIELD, D. J. (1997). Sparse coding with an overcomplete basis set : A strategy employed by v1 ? *Vision research*, 37(23):3311–3325.
- [Pati *et al.*, 1993] PATI, Y. C., REZAIEFAR, R. et KRISHNAPRASAD, P. S. (1993). Orthogonal matching pursuit : Recursive function approximation with applications to wavelet decomposition. In *Signals, Systems and Computers*, pages 40–44. IEEE.

- [Paulraj *et al.*, 1986] PAULRAJ, A., ROY, R. et KAILATH, T. (1986). A subspace rotation approach to signal parameter estimation. *Proceedings of the IEEE*, 74(7):1044–1046.
- [Peng *et al.*, 2017] PENG, H., LI, B., LING, H., HU, W., XIONG, W. et MAYBANK, S. J. (2017). Salient object detection via structured matrix decomposition. *IEEE transactions on pattern analysis and machine intelligence*, 39(4):818–832.
- [Penrose, 1946] PENROSE, L. S. (1946). The elementary statistics of majority voting. *Journal of the Royal Statistical Society*, 109(1):53–57.
- [Perona et Malik, 1990] PERONA, P. et MALIK, J. (1990). Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on pattern analysis and machine intelligence*, 12(7):629–639.
- [Power et Wilson, 2000] POWER, G. J. et WILSON, K. S. (2000). Segmenting shadows from synthetic aperture radar imagery using edge-enhanced region growing. In *Algorithms and Systems for Optical Information Processing IV*, volume 4113, pages 106–115. International Society for Optics and Photonics.
- [Prewitt, 1970] PREWITT, J. M. (1970). Object enhancement and extraction. *Picture processing and Psychopictorics*, 10(1):15–19.
- [Radoi, 1999] RADOI, E. (1999). *Contribution à la reconnaissance des objets 3D à partir de leur signature électromagnétique*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Rami *et al.*, 2014] RAMI, H., EL MALIANI, A. D., EL HASSOUNI, M. et BERTHOUMIEU, Y. (2014). Rotation-invariant texture retrieval using a steerable gaussian copula model. In *IEEE International Conference on Image Processing (ICIP)*, pages 2983–2987. IEEE.
- [Ranjani et Thiruvengadam, 2010] RANJANI, J. J. et THIRUVENGADAM, S. (2010). Dual-tree complex wavelet transform based SAR despeckling using interscale dependence. *IEEE Transactions on Geoscience and Remote Sensing*, 48(6):2723–2731.
- [Ratcliffe, 1997] RATCLIFFE, C. P. (1997). Damage detection using a modified laplacian operator on mode shape data. *Journal of Sound and Vibration*, 204(3):505–517.
- [Rebollo-Neira et Lowe, 2002] REBOLLO-NEIRA, L. et LOWE, D. (2002). Optimized orthogonal matching pursuit approach. *IEEE Signal Processing Letters*, 9(4):137–140.
- [Refaeilzadeh *et al.*, 2009] REFAEILZADEH, P., TANG, L. et LIU, H. (2009). Cross-validation. In *Encyclopedia of database systems*, pages 532–538. Springer.
- [Richards *et al.*, 2010] RICHARDS, M. A., SCHEER, J., HOLM, W. A. et MELVIN, W. L. (2010). Principles of modern radar. In *SciTech Pub*.
- [Rochdi, 2011] ROCHDI, M. (2011). *Signature électromagnétique bistatique d’une cible complexe placée sur une surface maritime rugueuse : modélisation, simulation et expérimentation*. Thèse de doctorat, Université de Bretagne occidentale-Brest.

- [Ross *et al.*, 1998] ROSS, T. D., WORRELL, S. W., VELTEN, V. J., MOSSING, J. C. et BRYANT, M. L. (1998). Standard SAR ATR evaluation experiments using the MSTAR public release data set. In *Algorithms for Synthetic Aperture Radar Imagery V*, volume 3370, pages 566–574. International Society for Optics and Photonics.
- [Rubinstein *et al.*, 2010] RUBINSTEIN, R., BRUCKSTEIN, A. M. et ELAD, M. (2010). Dictionaries for sparse representation modeling. *Proceedings of the IEEE*, 98(6):1045–1057.
- [Ruohong *et al.*, 2010] RUOHONG, H., KEJI, M., YANJING, L., JIMING, Y. et MING, X. (2010). SAR target recognition with data fusion. In *2010 WASE International Conference on Information Engineering*, volume 2, pages 19–23.
- [Ruohong et Ruliang, 2008] RUOHONG, H. et RULIANG, Y. (2008). SAR target recognition based on MRF and gabor wavelet feature extraction. In *IEEE International Geoscience and Remote Sensing Symposium*, volume 2, pages II–907. IEEE.
- [Saidi, 2010] SAIDI, M. N. (2010). *Reconnaissance de formes et d’objets en environnement incertain : application à la reconnaissance de cibles radar*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [SAIDI *et al.*, 2009] SAIDI, N., TOUMI, A., KHENCHAF, A., ABOUTAJDINE, D. et BRIGITTE, H. (2009). Feature extraction and fusion for automatic target recognition based ISAR images. *INFOCOMP*, 8(4):1–10.
- [Saunders, 2002] SAUNDERS, M. (2002). PDCO : Primal-dual interior-point method for convex objectives. *Systems Optimization Laboratory, Stanford University*.
- [Siagian et Itti, 2007] SIAGIAN, C. et ITTI, L. (2007). Rapid biologically-inspired scene classification using features shared with visual attention. *IEEE transactions on pattern analysis and machine intelligence*, 29(2):300–312.
- [Sklar, 1959] SKLAR, M. (1959). Fonctions de repartition en dimensions et leurs marges. *Publ. Inst. Statist. Univ. Paris*, 8:229–231.
- [Song *et al.*, 2014] SONG, B., LI, J., DALLA MURA, M., LI, P., PLAZA, A., BIOUCAS-DIAS, J. M., BENEDIKTSSON, J. A. et CHANUSSOT, J. (2014). Remotely sensed image classification using sparse representations of morphological attribute profiles. *IEEE transactions on geoscience and remote sensing*, 52(8):5122–5136.
- [Song *et al.*, 2016a] SONG, H., JI, K., ZHANG, Y., XING, X. et ZOU, H. (2016a). Sparse representation-based SAR image target classification on the 10-class mstar data set. *Applied Sciences*, 6(1):26.
- [Song *et al.*, 2016b] SONG, S., XU, B. et YANG, J. (2016b). SAR target recognition via supervised discriminative dictionary learning and sparse representation of the SAR-hog feature. *Remote Sensing*, 8(8):683.
- [Srinivas *et al.*, 2011] SRINIVAS, U., MONGA, V. et RAJ, R. G. (2011). Meta-classifiers for exploiting feature dependencies in automatic target recognition. In *Radar Conference (RADAR)*, pages 147–151. IEEE.

- [Sugeno et Kang, 1988] SUGENO, M. et KANG, G. (1988). Structure identification of fuzzy model. *Fuzzy sets and systems*, 28(1):15–33.
- [Sun et al., 2016] SUN, Y., DU, L., WANG, Y., WANG, Y. et HU, J. (2016). SAR automatic target recognition based on dictionary learning and joint dynamic sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 13(12):1777–1781.
- [Sun et al., 2005] SUN, Y., LIU, Z., TODOROVIC, S. et LI, J. (2005). Synthetic aperture radar automatic target recognition using adaptive boosting. In *Algorithms for Synthetic Aperture Radar Imagery XII*, volume 5808, pages 282–294. International Society for Optics and Photonics.
- [Sun et al., 2007] SUN, Y., LIU, Z., TODOROVIC, S. et LI, J. (2007). Adaptive boosting for SAR automatic target recognition. *IEEE Transactions on Aerospace and Electronic Systems*, 43(1).
- [Sun et al., 2013] SUN, Z., XUE, L. et XU, Y. (2013). Recognition of SAR target based on multilayer auto-encoder and snn. *International Journal of Innovative Computing, Information and Control*, 9(11):4331–4341.
- [Sweldens, 1996] SWELDENS, W. (1996). The lifting scheme : A custom-design construction of biorthogonal wavelets. *Applied and computational harmonic analysis*, 3(2):186–200.
- [Thiagarajan et al., 2010] THIAGARAJAN, J. J., RAMAMURTHY, K. N., KNEE, P., SPANIAS, A. et BERISHA, V. (2010). Sparse representations for automatic target classification in SAR images. In *4th International Symposium on Communications, Control and Signal Processing (ISCCSP)*, pages 1–4. IEEE.
- [Tison et al., 2004] TISON, C., NICOLAS, J., TUPIN, F. et MAÎTRE, H. (2004). A new statistical model of urban areas in high resolution SAR images for markovian segmentation. *IEEE Trans. on Geoscience and Remote Sensing*, 42(10):2046–2057.
- [Tison et al., 2007] TISON, C., POURTHIÉ, N. et SOUYRIS, J.-C. (2007). Target recognition in SAR images with support vector machines (SVM). In *IEEE International Geoscience and Remote Sensing Symposium*, pages 456–459. IEEE.
- [Toumi, 2007] TOUMI, A. (2007). *Intégration des bases de connaissances dans les systèmes d’aide à la décision : application à l’aide à la reconnaissance de cibles radar non-coopératives*. Thèse de doctorat, Université de Bretagne occidentale-Brest.
- [Toumi et al., 2007] TOUMI, A., HOELTZENER, B. et KHENCHAF, A. (2007). Using watersheds segmentation on ISAR image for automatic target recognition. In *2nd International Conference on Digital Information Management*, volume 1, pages 285–290. IEEE.
- [Toumi et al., 2009] TOUMI, A., HOELTZENER, B. et KHENCHAF, A. (2009). Hierarchical segmentation on ISAR image for target recognition. *International Journal of Computational research*, 5:63–71.

- [Toumi et Khenchaf, 2010] TOUMI, A. et KHENCHAF, A. (2010). Log-polar and polar image for recognition targets. *In 2010 IEEE International Geoscience and Remote Sensing Symposium*, pages 1609–1612.
- [Toumi et Khenchaf, 2013] TOUMI, A. et KHENCHAF, A. (2013). Système d'information pour l'aide à la reconnaissance de cibles radar. *In SCIGRAD'13, 27 octobre 2013, Brest, France*.
- [Toumi et Khenchaf, 2017] TOUMI, A. et KHENCHAF, A. (2017). Aircrafts recognition using convolutional neurons network. *In International Conference on Radar Systems, RADAR'17*.
- [Toumi et al., 2012] TOUMI, A., KHENCHAF, A. et HOELTZENER, B. (2012). A retrieval system from inverse synthetic aperture radar images : Application to radar target recognition. *Information Sciences*, 196:73–96.
- [Treisman et Gelade, 1980] TREISMAN, A. M. et GELADE, G. (1980). A feature-integration theory of attention. *Cognitive psychology*, 12(1):97–136.
- [Tropp et Wright, 2010] TROPP, J. A. et WRIGHT, S. J. (2010). Computational methods for sparse solution of linear inverse problems. *Proceedings of the IEEE*, 98(6):948–958.
- [Vapnik, 1995] VAPNIK, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer-Verlag New York, Inc., New York, NY, USA.
- [Voisin et al., 2014] VOISIN, A., KRYLOV, V. A., MOSER, G., SERPICO, S. B. et ZERUBIA, J. (2014). Supervised classification of multisensor and multiresolution remote sensing images with a hierarchical copula-based approach. *IEEE Transactions on Geoscience and remote sensing*, 52(6):3346–3358.
- [Von Hippel, 2005] VON HIPPEL, P. T. (2005). Mean, median, and skew : Correcting a textbook rule. *Journal of Statistics Education*, 13(2).
- [Wang et al., 2010] WANG, F., SHENG, W., MA, X. et WANG, H. (2010). Target automatic recognition based on ISAR image with wavelet transform and MBLBP. *In 2010 International Symposium on Signals, Systems and Electronics*, volume 2, pages 1–4.
- [Wang et al., 2015] WANG, H., CHEN, S., XU, F. et JIN, Y. Q. (2015). Application of deep-learning algorithms to MSTAR data. *In 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 3743–3745.
- [Wang et al., 2014] WANG, X., SHAO, Z., ZHOU, X. et LIU, J. (2014). A novel remote sensing image retrieval method based on visual salient point features. *Sensor Review*, 34(4):349–359.
- [Wang et al., 2017] WANG, Z., DU, L., ZHANG, P., LI, L., WANG, F., XU, S. et SU, H. (2017). Visual attention-based target detection and discrimination for high-resolution SAR images in complex scenes. *IEEE Transactions on Geoscience and Remote Sensing*.
- [Wang et al., 2018] WANG, Z., DU, L., ZHANG, P., LI, L., WANG, F., XU, S. et SU, H. (2018). Visual attention-based target detection and discrimination for high-resolution

- SAR images in complex scenes. *IEEE Transactions on Geoscience and Remote Sensing*, 56(4):1855–1872.
- [Wei *et al.*, 2008] WEI, G., QINGWEN, Q., LILI, J. et PING, Z. (2008). A new method of SAR image target recognition based on adaboost algorithm. In *International Geoscience and Remote Sensing Symposium*, volume 3, pages III–1194. IEEE.
- [Wickerhauser, 1996] WICKERHAUSER, M. V. (1996). *Adapted wavelet analysis : from theory to software*. AK Peters/CRC Press.
- [William, 1983] WILLIAM, J. (1983). The principles of psychology.
- [Wold *et al.*, 1987] WOLD, S., ESBENSEN, K. et GELADI, P. (1987). Principal component analysis. *Chemometrics and intelligent laboratory systems*, 2(1-3):37–52.
- [Wolfe *et al.*, 2010] WOLFE, J. M., PALMER, E. M. et HOROWITZ, T. S. (2010). Reaction time distributions constrain models of visual search. *Vision research*, 50(14):1304–1311.
- [Wright *et al.*, 2009a] WRIGHT, J., YANG, A. Y., GANESH, A., SASTRY, S. S. et MA, Y. (2009a). Robust face recognition via sparse representation. *IEEE transactions on pattern analysis and machine intelligence*, 31(2):210–227.
- [Wright *et al.*, 2009b] WRIGHT, S. J., NOWAK, R. D. et FIGUEIREDO, M. A. (2009b). Sparse reconstruction by separable approximation. *IEEE Transactions on Signal Processing*, 57(7):2479–2493.
- [Wu *et al.*, 2017] WU, Y., LIU, H., YUAN, J. et ZHANG, Q. (2017). Is visual saliency useful for content-based image retrieval? *Multimedia Tools and Applications*, pages 1–24.
- [Xiang *et al.*, 2018] XIANG, Y., WANG, F. et YOU, H. (2018). Os-sift : A robust sift-like algorithm for high-resolution optical-to-SAR image registration in suburban areas. *IEEE Transactions on Geoscience and Remote Sensing*, 56(6):3078–3090.
- [Xiao *et al.*, 2012] XIAO, B., MA, J.-F. et CUI, J.-T. (2012). Radial tchebichef moment invariants for image recognition. *Journal of Visual Communication and Image Representation*, 23(2):381–386.
- [Xing *et al.*, 2013] XING, X., JI, K., ZOU, H., CHEN, W. et SUN, J. (2013). Ship classification in terraSAR-x images with feature space based sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 10(6):1562–1566.
- [Xing *et al.*, 2014] XING, X., JI, K., ZOU, H. et SUN, J. (2014). Sparse representation based SAR vehicle recognition along with aspect angle. *The Scientific World Journal*, 2014.
- [Yan *et al.*, 2009] YAN, F., MEI, W. et CHUNQIN, Z. (2009). SAR image target recognition based on hu invariant moments and SVM. In *Information Assurance and Security, 2009. IAS'09. Fifth International Conference on*, volume 1, pages 585–588. IEEE.
- [Yang *et al.*, 2009] YANG, S., WANG, M. et JIAO, L. (2009). Radar target recognition using contourlet packet transform and neural network approach. *Signal Processing*, 89(4):394–409.

- [Yang *et al.*, 2005] YANG, Y., QIU, Y. et LU, C. (2005). Automatic target classification - experiments on the mstar SAR images. *In Sixth International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing and First ACIS International Workshop on Self-Assembling Wireless Network*, pages 2–7.
- [Yu *et al.*, 2018] YU, M., DONG, G., FAN, H. et KUANG, G. (2018). SAR target recognition via local sparse representation of multi-manifold regularized low-rank approximation. *Remote Sensing*, 10(2):211.
- [Yu *et al.*, 2011] YU, X., LI, Y. et JIAO, L. C. (2011). SAR automatic target recognition based on classifiers fusion. *In 2011 International Workshop on Multi-Platform/Multi-Sensor Remote Sensing and Mapping*, pages 1–5.
- [Yuankui et Yiming, 2007] YUANKUI, H. et YIMING, Y. (2007). Automatic target recognition of ISAR images based on hausdorff distance. *In 2007 1st Asian and Pacific Conference on Synthetic Aperture Radar*, pages 477–479.
- [Zaied *et al.*, 2018] ZAIED, S., TOUMI, A. et KHENCHAF, A. (2018). Target classification using convolutional deep learning and auto-encoder models. *In 2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)*, pages 1–6.
- [Zhang *et al.*, 2012] ZHANG, H., NASRABADI, N. M., ZHANG, Y. et HUANG, T. S. (2012). Multi-view automatic target recognition using joint sparse representation. *IEEE Transactions on Aerospace and Electronic Systems*, 48(3):2481–2497.
- [Zhang *et al.*, 2014] ZHANG, L., DING, Z., LI, H., SHEN, Y. et LU, J. (2014). 3D face recognition based on multiple keypoint descriptors and sparse representation. *PloS one*, 9(6):e100120.
- [Zhang *et al.*, 2001] ZHANG, Y., BRADY, M. et SMITH, S. (2001). Segmentation of brain mr images through a hidden markov random field model and the expectation-maximization algorithm. *IEEE transactions on medical imaging*, 20(1):45–57.
- [Zheng *et al.*, 2017] ZHENG, L., YANG, Y. et TIAN, Q. (2017). SIFT meets CNN : A decade survey of instance retrieval. *IEEE transactions on pattern analysis and machine intelligence*.

Titre : Traitement et classification parcimonieuse des images radar pour l'aide à la reconnaissance de cibles

Mots clés : *images radar (ISAR/SAR), saillance visuelle, SIFT, transformées en ondelettes, modélisation statistique, classification parcimonieuse, reconnaissance automatique de cibles.*

Résumé : La reconnaissance automatique de cibles est toujours une problématique d'intérêt dans différents domaines d'application (sécurité, surveillance, automobile, environnement, médecine, ...). Dans le cadre du travail réalisé, nous nous sommes intéressés au développement d'une méthodologie dédiée à la reconnaissance de cibles à partir des images radar à synthèse d'ouverture (directe ou inverse). Dans ce contexte, différentes techniques développées dans la littérature souffrent de certaines lacunes selon la nature des données traitées (hétérogènes, multimodales, ...), la précision, la robustesse vis-à-vis du bruit et le temps de calcul. Dans ce travail, l'objectif principal porte sur le développement d'outils pour l'aide à la reconnaissance de cibles à partir des images radar. Ainsi, deux bases de données d'images ont été considérées. D'une part des images ISAR (Inverse Synthetic Aperture Radar), récoltées dans la chambre anéchoïque de l'ENSTA Bretagne. Et d'autre part des images SAR (Synthetic Aperture Radar) de la base de données MSTAR. Pour atteindre l'objectif d'amélioration du processus de reconnaissance étudié et développé, et en dehors des

méthodes proposées au niveau du traitement et d'extraction de caractéristiques, nous nous sommes intéressés tout au long de la phase de reconnaissance à l'apport de la classification parcimonieuse des images radar. Dans ce sens, la première contribution porte sur la proposition d'un dictionnaire formé par les descripteurs SIFT (Scale Invariant Feature Transform) filtrés par la méthode de la saillance visuelle. Ensuite, en utilisant ce dictionnaire, une classification parcimonieuse multitâche est appliquée dans la phase de reconnaissance. Quant à la seconde contribution, elle intègre la modélisation statistique des images radar considérées dans le domaine des ondelettes complexe. Les paramètres statistiques résultants (univariés ou multivariés) ont été mis à profit pour construire un dictionnaire statistique. Ce dictionnaire est pondéré par la suite en utilisant une mesure de similarité qui intègre la KLD (Kullbak-Leibler Divergence) entre les paramètres statistiques. Les performances des deux contributions ont été évaluées empiriquement sur les deux bases de données distinctes d'images radar (ISAR et SAR).

Title : Treatement and sparse classification of radar images for automatic target recognition

Keywords : *radar images (ISAR/SAR), saliency attention, SIFT, wavelet transform, statistical modeling, sparse classifier, automatic target recognition.*

Abstract : Automatic target recognition has become a flourishing research topic in remote sensing. This problematic is of paramount importance in several military and civilian applications (security, surveillance, automobile, environment, medicine, ...). In this work, we focus on the development of new methodology dedicated to the target recognition from synthetic aperture radar images (inverse or direct). In this context, the different methods proposed in the literature have several drawbacks according to the type of used data (heterogeneous, multimodal, ...), the accuracy, the robustness to noise and the computation time. In this work, we aim to propose new methods for targets recognition from radar images. Thus, two different databases are considered. On the one hand, we use the ISAR (Inverse Synthetic Aperture Radar) images acquired from the anechoic chamber of ENSTA Bretagne. On the other hand, we exploit the SAR (Synthetic Aperture Radar) images of MSTAR database. To achieve the goal of the amelioration of the recognition process studied and

developed, we give a special interest to the SRC (Sparse Representation-based Classification) method to recognize the radar images. This method includes also the processing and feature extraction steps to build the dictionary. In this optic, the first contribution consists on constructing a new dictionary composed by the SIFT (Scale Invariant Feature Transform) descriptors filtered by the saliency attention method. After that, this dictionary is exploited by a multitask sparse classifier to achieve the recognition step. In the second contribution, we statistically model the radar images in the complex wavelet domain. The resulting statistical parameters (univariate or multivariate) are stacked together to construct the statistical dictionary. Afterwards, this dictionary is weighted by using a similarity measure that includes the KLD (Kullbak-Leibler Divergence) between the statistical parameters. The performances of the two proposed methods have been evaluated empirically on two different databases of radar images (ISAR and SAR).