

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE DE TECHNOLOGIE
DEPARTEMENT D'ELECTRONIQUE
N° :



DOMAINE : SCIENCE ET TECHNOLOGIE
FILIERE : ELECTRONIQUE
OPTION : ...INSTRUMENTATION.....

**Mémoire présenté pour l'obtention
Du diplôme de Master Académique**

Par:

KERMAYA Nour Djihene

et

ABD ELKEBIR Amel

Intitulé

**Estimation des Paramètres du
Clutter CGIG par la Technique
d'Intelligence Artificielle**

Soutenu devant le jury composé de:

| | | |
|------------------|-----------------------------------|------------|
| Oudira Houcine | Université Mohamed Boudiaf M'sila | Président |
| Mezache Amar | Université Mohamed Boudiaf M'sila | Rapporteur |
| Benahcene Madani | Université Mohamed Boudiaf M'sila | Examineur |

Année universitaire : 2022 / 2023

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Résumé

La bonne modélisation et la bonne estimation des paramètres du clutter de la mer rendent la détection des cibles radar plus performante. Les travaux de ce mémoire concernent deux volets ; la modélisation des échos radar IPIX (Intelligent Pixel X-band) et l'application de la technique du réseau de neurones artificielle (ANN) pour l'estimation des paramètres du modèle de clutter. Pour ce faire, nous proposons en premier temps la distribution gaussienne composée (CGIG) et la distribution mélangée CGIG. Un ajustement précis de ce type de données est obtenu par rapport aux distributions standards nommées Weibull, log-normal, Pareto type II et K . Ensuite, l'intelligence artificielle basée sur les réseaux de neurones MLP (Multilayer Perceptron) est appliquée dans le but d'acquérir des estimés rapides des paramètres du modèle CGIG. A cet effet, la phase d'apprentissage, la phase de test et la phase de validation sont considérées pour la construction de l'estimateur ANN.

Abstract

Good modeling and good estimation of sea clutter parameters make radar target detection more effective. The work of this Master thesis concerns two aspects; the modeling of IPIX (Intelligent Pixel X-band) radar echoes and the application of the artificial neural network (ANN) technique for estimating the parameters of clutter model. To do this, we first propose the compound Gaussian distribution (CGIG) and the mixture CGIG distribution. The best fitting to this kind of data is obtained against standard distributions labeled Weibull, log-normal, Pareto type II and K . Then, the ANN MLP (Multilayer Perceptron) is applied for the purpose of acquiring rapid estimates of CGIG model parameters. For this intention, the learning phase, the test phase and the validation phase are considered for the construction of the ANN estimator.

ملخص

إن النمذجة الجيدة والتقدير الجيد لثوابت فوضى البحر تجعل الكشف عن هدف الرادار أكثر فعالية. العمل المقدم في هذه المذكرة يتعلق بجانبين؛ نمذجة أصداء الرادار IPIX (Intelligent Pixel X-band) و تطبيق تقنية الشبكة العصبية الاصطناعية (ANN) لتقدير ثوابت نموذج فوضى البحر. للقيام بذلك، نقترح أولاً النموذج CGIG و النموذج المزيج CGIG. لقد تم الحصول على أفضل ملائمة لهذا النوع من الفوضى مقارنة بالتوزيعات الإحصائية المسماة Weibull، Pareto type II، log-normal و K. ثم تم تطبيق تقنية الشبكة العصبية الاصطناعية (Multilayer Perceptron) MLP ANN لغرض الحصول على تقديرات سريعة لثوابت النموذج CGIG من أجل هذه الغاية، لقد أجرينا ثلاثة مراحل، مرحلة التعلم، مرحلة الاختبار ومرحلة المصادقة من أجل بناء المقدر ANN.

Remerciements

Tout d'abord, nous devons remercier **ALLAH** qui nous à donner la santé et la volonté au cours de notre étude et la réalisation de ce mémoire.

Nous adressons notre gratitude et nous remercions infiniment notre encadreur **Pr. Mezache Amar** et la doctorante **Terki Zakia** pour leurs encadrement, leurs conseils, leurs recommandations tout au long de ce travail et sur toutes les heures consacrées à diriger ce travail, pour leurs suivi scientifique, pour leurs confiance et pour leurs efforts.

Nos sincères remerciements vont également aux membres de Jury, **Pr. Oudira Houcine** en tant que président et **Dr. Benahcene Madani** en tant que examinateur pour la confiance et l'intérêt qu'ils nous ont accordé en acceptant d'évaluer ce travail.

Enfin, nous souhaiterions aussi adresser nos gratitude aux enseignants du département d'Electronique qui'ils nous ont appris et soutenus notre formation de Master en Electronique spécialité « Instrumentation ».

DEDICACE

أهدي هذه المذكرة إلى التي رافقتني بروحها وإن فارقتني بجسدها إلى من كانت لي
سندا و عوناً عند الشدائد أمي الحبيبة -عائشة بوحيتم- رحمها الله.
إلى الذي جد و بذل كل جهده لدعمي أبي العزيز-أحمد-.
إلى من شد الله بهم عضدي فكانوا خير معين أخي -بدرالدين- و أختي -إيمان-
إلى السند الذي منحني القوة في مسيرتي خالي -أحمد مستيري-.
إلى جميع الأصدقاء و كل من مد يد العون لي و ساعدني ولو بحرف واحد في حياتي
الدراسية.

Nour Djihene

DEDICACE

Je dédie ce mémoire à celui qui m'a encouragé à persévérer tout au long de ma vie à l'homme le plus éminent de ma vie (mon cher père), à celui en qui j'ai suis au-dessus et sur qui je compte sur la chérie de mon cœur (ma chère maman), je les remercie d'avoir sacrifié leur vie pour ma réussite et de m'éclairer la voie avec leurs sages conseils, j'espère un jour pouvoir rembourser un peu de ce qu'ils ont fait pour moi...

Je dédie également ce travail à mes sœurs Wasila, Somaya et mon frère Oussama, et à mon neveu Al-Katkoot (Qais).....

Je voudrais dédier ce travail à tous les membres de ma famille estimée, et à mes amies Fatima, Ahlam, Fatiha, Donia, Rawya et Samia qui ont toujours étaient avec moi....

Amel

Sommaire

| | |
|---|------|
| Résumé | ii |
| Remerciements | v |
| Dédicace | vi |
| Liste des Figures | xi |
| Liste des Tableaux | xiii |
| Liste des Abréviations | xiv |
| Liste des Symboles | xv |
| Introduction générale | 1 |
| 1. Introduction..... | 1 |
| 2. Etat de l'art..... | 2 |
| 3. Travaux du mémoire..... | 2 |
| 4. Organisation du mémoire..... | 3 |
| Chapitre 1 : Les Radars | 4 |
| 1. 1 Introduction..... | 4 |
| 1. 2 Historique et applications du radar..... | 5 |
| 1. 2. 1 Applications..... | 8 |
| 1. 3 Principe du radar..... | 9 |
| 1. 4 Types de radar..... | 10 |
| 1. 4. 1 Radar primaire (ou imageurs)..... | 11 |
| 1. 4. 2 Radar secondaires..... | 12 |
| 1. 5 Modèles de Swerling de cibles..... | 12 |
| 1. 6 Modélisation du clutter..... | 13 |
| 1. 6. 1 Clutter de volume..... | 14 |
| 1. 6. 2 Clutter de surface..... | 14 |
| 1. 7 Conclusion..... | 18 |

| | |
|---|-----------|
| Chapitre 2 : Modélisation du clutter par les lois CGIG et mixture CGIG..... | 19 |
| 2. 1 Introduction..... | 19 |
| 2. 2 Modèles de clutter de mer avec ses estimateurs | 20 |
| 2. 2. 1 Distribution Weibull et la méthode MLE..... | 21 |
| 2. 2. 2 Distribution log-normal et la méthode MLE..... | 21 |
| 2. 2. 3 Distribution Pareto type II et la méthode MLE..... | 22 |
| 2. 2. 4 Distribution K et ses estimateurs..... | 22 |
| 2. 2. 5 Distribution CGIG et la méthode MLE..... | 24 |
| 2. 2. 6 Distribution CGIG mixture et la méthode LSA..... | 24 |
| 2. 3 Performances de la modélisation | 25 |
| 2. 4 Conclusion..... | 32 |
| Chapitre 3 : Estimation des paramètres du clutter CGIG basée sur le ANN..... | 36 |
| 3. 1 Introduction..... | 33 |
| 3. 2 Méthodes d'estimation existante..... | 34 |
| 3. 2. 1 Méthode des moments entiers..... | 34 |
| 3. 2. 2 Méthode des moments fractionnaires..... | 35 |
| 3. 2. 3 Méthode $z\log(z)$ | 35 |
| 3. 2. 4 Méthode MLE..... | 35 |
| 3. 3 Estimation par le ANN | 36 |
| 3. 3. 1 Généralités sur le ANN..... | 36 |
| 3. 3. 2 Réseau de neurones à apprentissage profond (DL)..... | 39 |
| 3. 3. 3 Architecture du RN-LSTM..... | 40 |
| 3. 3. 4 Architecture de l'estimateur ANN proposée..... | 41 |
| 3. 4 Comparaison des résultats d'estimation..... | 43 |
| 3. 4. 1 Phase d'apprentissage..... | 43 |
| 3. 4. 2 Phase de test..... | 43 |
| 3. 4. 3 Phase de validation..... | 48 |

| | |
|---------------------------------|-----------|
| 3. 5 Conclusion..... | 52 |
| Conclusion Générale..... | 53 |
| 1. Introduction..... | 53 |
| 2. Synthèse du mémoire | 54 |
| 3. Travaux futurs | 55 |
| Référence..... | 56 |

Liste des Figures

| | |
|--|----|
| Figure 1. 1 : Radar Limber Freya à membrures..... | 6 |
| Figure 1. 2 : Radar NEXRAD situé au centre d'opérations radar WSR-88D..... à Norman, Oklahoma | 8 |
| Figure 1. 3 : Scénario illustrant le principe du radar..... | 10 |
| Figure 1. 4 : Détection des cibles maritimes par le radar..... | 10 |
| Figure 1. 5 : Types de radars..... | 11 |
| Figure 1. 6 : Détecteur d'amplitude des échos radar..... | 14 |
| Figure 2. 1 : Illustration de la modélisation pour la polarisation HH,..... résolution 3 m et la 17ème cellule de portée. | 28 |
| Figure 2. 2 : Illustration de la modélisation pour la polarisation HH,..... résolution 3 m et la 5ème cellule de portée | 28 |
| Figure 2. 3 : Illustration de la modélisation pour la polarisation VV,..... résolution 3 m et la 13ème cellule de portée. | 29 |
| Figure 2. 4 : Illustration de la modélisation pour la polarisation HH,..... résolution 15 m et la 23ème cellule de portée | 29 |
| Figure 2. 5 : Illustration de la modélisation pour la polarisation VV,..... résolution 15 m et la 8ème cellule de portée. | 30 |
| Figure 2. 6 : Illustration de la modélisation pour la polarisation HH,..... résolution 30 m et la 25ème cellule de portée. | 30 |
| Figure 2. 7 : Illustration de la modélisation pour la polarisation VV,..... résolution 30 m et la 7ème cellule de portée. | 31 |
| Figure 2. 8 : Illustration de la modélisation pour la polarisation VH,..... et 12ème cellule de portée | 31 |
| Figure 2. 9 : Illustration de la modélisation pour la polarisation HV,..... et 12ème cellule de portée. | 32 |
| Figure 3. 1 : Structure du réseau de neurones non-récurrent..... (a) Neurone formel. (b) Réseau de neurone organisé en couches. | 38 |
| Figure 3. 2 : Entraînement du réseau de neurone non-récurrent..... | 39 |

| | |
|--|----|
| Figure 3. 3 : Architecture proposée de l'estimateur ANN..... | 42 |
| des paramètres de la distribution CGIG | |
| Figure 3. 4 : Entraînement du réseau de neurones pour $N = 500$ et $\mu = 1$ | 44 |
| Figure 3. 5 : Entraînement du réseau de neurones pour $N = 1000$ et $\mu = 1$ | 44 |
| Figure 3. 6 : Entraînement du réseau de neurones pour $N = 10000$ et $\mu = 1$ | 45 |
| Figure 3. 7 : Phase de test du réseau de neurones pour $N = 500$ et $\mu = 1$ | 45 |
| Figure 3. 8 : Phase de test du réseau de neurones pour $N = 1000$ et $\mu = 1$ | 46 |
| Figure 3. 9 : Phase de test du réseau de neurones pour $N = 10000$ et $\mu = 1$ | 46 |
| Figure 3. 10 : Comparaison des MSEs utilisant les approches d'estimation..... | 47 |
| zlog(z), MLE et ANN pour $n = 100$, $N = 500$ et $\mu = 1$ | |
| Figure 3. 11 : Comparaison des MSE utilisant les approches d'estimation..... | 48 |
| Figure 3. 12 : Comparaison des MSE utilisant les approches d'estimation..... | 48 |
| zlog(z), MLE et ANN pour $n = 100$, $N = 10000$ et $\mu = 1$ | |
| Figure 3. 13 : Performances de l'estimation ANN pour une résolution..... | 49 |
| 3m, 3ème cellule et polarisation HH. | |
| Figure 3. 14 : Performances de l'estimation ANN pour une résolution..... | 50 |
| 15m, 14ème cellule et polarisation HH | |
| Figure 3. 15 : Performances de l'estimation ANN pour une résolution..... | 50 |
| 30m, 2ème cellule et polarisation HH. | |
| Figure 3. 16 : Performances de l'estimation ANN pour une résolution..... | 51 |
| 3m, 20ème cellule et polarisation VV. | |
| Figure 3. 17 : Performances de l'estimation ANN pour une résolution..... | 51 |
| 15m, 22ème cellule et polarisation VV. | |
| Figure 3. 18 : Performances de l'estimation ANN pour une résolution..... | 52 |
| 30m, 15ème cellule et polarisation VV. | |

Liste des Tableaux

| | |
|---|----|
| Table. 1. 1: Historique du système radar et sa fonctionnalité..... | 7 |
| Table. 1. 2: Domaines d'applications du radar..... | 9 |
| Table. 2. 1: Détails techniques du fichier « 19931118_162155_stareC0000.cdf »..... | 27 |

Liste des Abréviations

| | |
|------------------|--|
| CFAR | Constant False Alarm Rate |
| CG-IG | Compound Gaussian-Inverse Gaussian |
| IPIX | Intelligent Pixel X-band |
| MLE | Maximum Likelihood Estimation |
| LSA | Least Squares Approximation |
| MLP | Multilayer Perceptron |
| ANN | Artificial Neural Networks |
| RADAR | RAdio Detection And Ranging |
| TSF | Transmission Sans Fil |
| WSR-88D | Weather Surveillance Radar, 1988, Doppler |
| GC | General Compound |
| pdf | Probability Density Function |
| MAP | Maximum A Posteriori |
| PCFE | Parametric Curve Fitting Estimation (Nelder-Mead algorithm) |
| LF | Likelihood Function |
| LLF | Log-LF |
| CCDF | Cumulative Distributed Function |
| HH/VV | Antennas polarisation (Horizontal-Horizontal /Vertical-Vertical) |
| PRF | Pulse Repetition Frequency |
| GLRT-CFAR | Generalized Likelihood Ratio Test CFAR |
| DL | Deep-Learning |
| PMC | Perception Multi Couches |
| LSTM-NN | log-short Term Memory Neural Networks |
| MSE | Mean Square Error of Estimates |

Liste des Symboles

| | |
|-------------------------|--|
| $\Gamma(.)$ | La fonction gamma |
| σ | Écart-type |
| α | Paramètre de forme de la distribution de Pareto (simple ou composée) |
| β | Paramètres d'échelle de la distribution de Pareto type II |
| σ^2 | Variance. |
| φ | Phase |
| $\langle \cdot \rangle$ | Moyenne empirique |
| $\hat{\sigma}$ | Ecart type estimé de la variable $\log(x)$ |
| Q | Composante en quadrature |
| $\hat{\mu}$ | Moyenne estimée |
| μ | Médian. |
| ν | Paramètre de forme de la distribution K |
| $\ln(x)$ | Log de la variable aléatoire |
| C | Vitesse de la lumière |
| R | Portée des radars |
| N | Nombre des impulsions |
| λ | Paramètre de forme de la distribution |
| P_{FA} | Probabilité de fausse alarme |
| T | Seuil de détection |
| \tilde{A} | Amplitude reçue |
| $\hat{\theta}$ | Vecteur de paramètres estimés |
| $E_i(.)$ | La fonction exponentielle-intégrale |
| $\langle x^r \rangle$ | Moment d'ordre r |
| ${}_2F_0(\dots)$ | Fonction hypergéométrique confluyente |
| T_i | Seuil normalisés |
| $K(.,.)$ | Fonction de Bessel modifiée |

Introduction Générale

Sommaire de l'introduction générale :

| | |
|---------------------------------|---|
| 1. Introduction..... | 1 |
| 2. Etat de l'art..... | 2 |
| 3. Travaux du mémoire..... | 2 |
| 4. Organisation du mémoire..... | 3 |

1. Introduction

Le radar est un système de radiolocalisation qui utilise les ondes radio pour déterminer plusieurs paramètres tels que la distance ou portée, l'angle d'azimut et la vitesse radiale des objets par rapport au site. Le radar a été développé secrètement pour une utilisation militaire par plusieurs pays dans la période avant et pendant la Seconde Guerre mondiale. L'un des développements clés a été le magnétron cavité au Royaume-Uni, qui a permis la création de systèmes relativement petits avec résolution sous-mètre. Le terme RADAR a été inventé en 1940 par la Marine des États-Unis comme acronyme pour la détection et la télédétection radio. Le terme radar est entré depuis dans l'anglais et d'autres langues comme nom commun, perdant toute capitalisation. Il est utilisé pour détecter et suivre les aéronefs, les navires, les engins spatiaux, les missiles guidés et les véhicules à moteur, et cartographier les formations météorologiques et le terrain. Un système radar consiste en deux blocs de préparation de signaux à transmettre et à recevoir. Un émetteur produit des ondes électromagnétiques avec des fréquences de propagation généralement élevées. Dans le domaine de la radio ou des micro-ondes, un radar mono statique est souvent employé dont la même antenne est utilisée pour l'émission et la réception. Le récepteur contient un processeur

pour le traitement et la détermination des propriétés des objets. En d'autres mots, les ondes radio (pulsées ou continues) de l'émetteur réfléchissent les cibles et retournent au récepteur, donnant des informations utiles sur l'emplacement et la vitesse des objets [1].

2. Etat de l'art

Le traitement de données radar utilise des algorithmes d'extraction des informations des cibles. A cet effet, la spécification des modèles statistiques des échos est très importante pour la construction des procédures de la poursuite, la détection, l'estimation, etc. C'est pour cette raison que plusieurs chercheurs s'intéressent sur l'étude statistique des retours radar d'une manière approfondie [2]. In terms of radar clutter conditions, non-Gaussian density functions have been deduced [3]. Pour une bonne représentation des statistiques de la mer ou du sol, la puissance du clutter est supposée une variable aléatoire de distribution gamma, gamma-inverse, log-normal, Gaussian-inverse, etc [4].

La procédure CFAR (Constant False Alarm Rate) adapte le seuil de détection d'une manière intelligente en fonction de l'estimation en temps réel de l'état de l'environnement [5]. Ce principe permet de maintenir les valeurs de la probabilité de fausse alarme autour de sa valeur désirée. Puisque l'environnement de détection peut avoir des situations différentes (homogène ou non-homogène), un nombre de détecteur CFAR est développé [6-8].

Nous avons mentionné ci-dessus que la tâche d'estimation des paramètres de clutter doit être effectuée pour adapter le seuil de détection. Par conséquent, l'approche d'estimation considérée dépend réellement du modèle statistique du clutter considéré [9]. On cherche toujours à développer des méthodes à formes compactes, rapides et efficaces. Cependant, ça ce n'est pas possible pour des modèles complexes représentant mieux les échos radar. Dans ce cas, l'approche d'estimation devient très complexe, car elle est basée sur les calculs d'intégrales en fonction de ces modèles mathématiques. Pour orienter cette complexité, l'intelligence artificielle basée sur les réseaux de neurones est appliquée [10].

3. Travaux du mémoire

Les travaux de recherche de ce mémoire concernent deux volets ; la modélisation des échos radar IPIX (Intelligent Pixel X-band) et l'application de la technique du réseau de neurones artificielle (ANN) pour l'estimation des paramètres. Ces deux contributions sont récapitulées comme suit :

Pour obtenir un ajustement précis des données réelles IPIX, la distribution gaussienne composée (CGIG) et la distribution mélangée CGIG sont proposées et évaluées devant les distributions standard Weibull, log-normal, Pareto type II et K . Les paramètres de ces distributions statistiques sont obtenus à l'aide des approches MLE (Maximum Likelihood Estimation) et LSA (Least squares Approximation).

Pour acquérir des valeurs d'estimation rapides des paramètres du modèle CGIG, l'intelligence artificielle basée sur les réseaux de neurones MLP (Multilayer Perceptron) est proposée dans ce mémoire. Pour ce faire, nous avons effectué trois phases de conception de l'estimateur ANN; la phase d'apprentissage, la phase de test et la phase de validation.

4. Organisation du mémoire

Le présent mémoire est organisé comme suit :

Le **Chapitre 1** présente en premier lieu l'hystérique et les applications radars. Après, il explique brièvement le principe de fonctionnement et les différents types de radars. Puis, il discute les modèles statistiques des cibles et du clutter de la mer de haute résolution.

Le **Chapitre 2** vise l'ajustement précis des données de la mer IPIX (Intelligent Pixel X-band, voir annexe A) en utilisant la distribution CGIG et la distribution mélangée CGIG. Pour évaluer les résultats de la modélisation, les modèles proposés sont comparés avec des distributions standard telles que Weibull, log-normal, Pareto type II et K . Pour ce faire, les paramètres de ses distributions sont estimés à partir d'un nombre fini d'échantillons de clutter de mer en utilisant la méthode MLE et la méthode LSA (Least Squares Approximation).

Le **Chapitre 3** rappelle d'abord les méthodes d'estimation basées sur les moments d'ordres entiers, fractionnaires, $\text{zlog}(z)$ et MLE. Il présente l'architecture des réseaux de neurones utilisée pour la prédiction des valeurs du paramètre de forme de la distribution CGIG. Après, il présente une série de comparaisons de l'estimation des approches $\text{zlog}(z)$, MLE et ANN utilisant des données simulées.

Enfin, une conclusion générale est présentée auprès des trois chapitres du mémoire.

Chapitre 1

Les Radars

Sommaire du chapitre :

| | |
|---|----|
| 1. 1 Introduction..... | 4 |
| 1. 2 Historique et applications du radar..... | 5 |
| 1. 3 Principe du radar..... | 9 |
| 1. 4 Types de radar..... | 10 |
| 1. 5 Modèles de Swerling de cibles..... | 12 |
| 1. 6 Modélisation du clutter..... | 13 |
| 1. 7 Conclusion..... | 18 |

1. 1 Introduction

Les systèmes radar ont énormément progressé depuis leurs débuts lorsque leurs fonctions étaient limitées à la détection et à la détermination de la portée des navires. En effet, le mot radar était à l'origine un acronyme qui signifiait « détection et télémétrie radio ». Le "RADAR" est par définition un appareil de "RADIO DÉTECTION AND RANGING" que l'on peut traduire par "détection et estimation de la distance des cibles par onde radio" [11]. Le développement des calculateurs numériques a rendu des systèmes radar d'être sophistiqués assurant une large gamme d'applications civils et militaires. Depuis 1842, plusieurs chercheurs ont contribué dans le développement de ce système qui est actuellement appliqué dans plusieurs domaines qu'on a vraiment besoin dans notre vie quotidienne telle que la sécurité routière, la médecine, la navigation maritime et aérienne, etc.

Dans ce chapitre, nous allons résumer en premier lieu l'hystérique et les applications radars. Après, on va expliquer brièvement le principe de fonctionnement et les différents types de radars. Puis, on va discuter les modèles statistiques des cibles et du clutter de haute résolution. Enfin, une conclusion des points essentiels abordés dans ce chapitre sont cités.

2. 2 Historique et applications du radar

À la fin des années 1880, le physicien allemand Heinrich Hertz a définitivement montré l'existence d'ondes électromagnétiques telles que formulées par James Clerk Maxwell dans ses travaux approfondis sur la théorie de l'électromagnétisme [12]. Au début 19^{ème} siècle, le développement de radio TSF (Transmission Sans Fil : qui est un mode de communication fondé sur l'utilisation d'ondes électromagnétiques modulées) a permis de mettre au point les antennes nécessaires à l'utilisation de la radio détection. Plusieurs inventeurs scientifiques et ingénieurs ont contribué au développement du radar.

D'abord en 1904, l'allemand Christian Hülsmeyer montre qu'il y a une possibilité de détecter la présence de navires dans un brouillard très dense à l'aide d'ondes radio électriques. Ensuite les expériences de détection avec des antennes radio se multiplient dans les années 1920 et 1930. En 1934, la France déposa un brevet sur un système de détection par ondes courtes : les premiers radars à ondes décimétriques équipent le cargo Oregon (en 1934) puis le paquebot Normandie (en 1935). En 1935, un brevet ait déposé par l'anglais Robert Watson-Watt, qui est généralement considéré comme l'inventeur "officiel" du radar. Les Britanniques mettent alors en place le premier réseau de radars sous le nom de "Chain home". Parallèlement, des recherches dans ce domaine sont également menées en Hongrie, en Allemagne et aux États-Unis. Des systèmes opérationnels ont ainsi pu être utilisés au cours de la Seconde Guerre mondiale. Pendant la Seconde Guerre mondiale, le radar fait partie des armes qui ont joué un rôle crucial dans le conflit. Dès 1937, les Allemands ont équipé leur marine, la Luftwaffe et l'Armée de terre de radars servant à corriger le tir.

La **Figure. 1. 1** est une illustration d'un radar allemand « Limber Freya » de la Seconde Guerre mondiale de TME 11-219 "Répertoire de l'équipement radar allemand". Au cours de ce conflit, l'expérience concrète au combat a poussé les ingénieurs et les scientifiques à apporter de nombreuses améliorations techniques à leur invention. C'est ainsi que les radars aéroportés ont été mis au point pour permettre les bombardements et la chasse de nuit. Cette expérience acquise par les opérateurs des radars pendant la guerre a également permis le développement de nouvelles applications [13-16].




Figure 1. 1 Radar Limber Freya à membrures

Les années 1950 ont vu l'émergence de radars de poursuite de haute précision et l'utilisation de l'amplificateur klystron pour les systèmes haute puissance et longue portée. Au cours des années 80, les améliorations apportées aux systèmes multiéléments, y compris la technologie des circuits à semi-conducteurs et à micro-ondes, ont rendu possible la télédétection des effets environnementaux tels que le cisaillement du vent. En 1990, un prototype opérationnel du WSR-88D (Weather Surveillance Radar, 1988, Doppler) a été achevé et la première installation de prévision météorologique quotidienne a été achevée à Sterling, Virginie (USA) en 1992. Il s'agissait du premier des systèmes radar de nouvelle génération (NEXRAD), qui est un réseau de 159 radars météorologiques Doppler à haute résolution (voir [Figure. 1. 2](#)). L'historique du système radar et sa fonctionnalité sont montrés par la [Table. 1. 1](#).

Même si au départ, le radar servait pour des opérations militaires. De nos jours l'utilisation du radar est étendue à d'autres domaines que le domaine militaire. On l'utilise dans l'aviation civile, l'astrométrie, le contrôle maritime, la détection météorologique et le contrôle du trafic routier (détecteurs de vitesse sur les routes). Par exemple en météorologie, l'informatique permet désormais de traiter les données radars en temps réel et d'utiliser des algorithmes pour repérer les précipitations dangereuses (orages, pluie diluvienne, rafales) et prévoir leur déplacement. Le radar est également utilisé pour protéger les installations civiles. Il est largement utilisé dans la reconnaissance et détection d'objets dangereux cachés ou de

structures instables (fortes tempêtes, bâtiments endommagés, plaques de neige en montagne, etc.). En plus de ça, nous considérons également d'autres applications illustrées dans la section suivante.

Table. 1. 1 Historique du système radar et sa fonctionnalité [13-16].

| Inventeur | Année | Fonction du système |
|---|--------------|---|
| Christian Doppler (physicien autrichien) | 1842 | Prédiction de vitesse des cibles détectées. |
| James Clerc Maxwell. (physicien écossais) | 1862 | Prédiction du rayonnement électromagnétique |
| Henri Hertz (physicien allemand) | 1886 | Propagation et réflexion des ondes radio à partir d'objets métalliques. |
| Guglielmo Marconi (ingénieur électricien italien) | 1899 | Les ondes radio sont réfléchies vers l'émetteur par des objets dans une balise radio expériences. |
| Christian Hulsmeyer (physicien allemand) | 1904 | Détection des navires afin que les collisions puissent à éviter et mesure du transit temps des ondes réfléchies |
| Charles-Samuel Franklin et G. Marconi | 1916 | Utilisation des ondes courtes dans les expériences, critique pour le développement pratique de radar |
| Robert Watson Watt | 1934 | Recherche de détection radio et radar technologie. |
| Accueil de la chaîne Britannique Prototype | 1936 | Système d'alerte précoce fourni directionnel informations aux objets sur de courtes distances. |
| 8 nations : Royaume-Uni, Allemagne, États-Unis, URSS... | 1936-1939 | Développement de systèmes radar modernes capable de produire de courtes impulsions radio énergie. |
| Royaume-Uni, États-Unis, URSS, ... (période II ware) | 1940-1945 | Développement du magnétron dans le Royaume-Uni, qui a permis la création de systèmes relativement petits. |
| Grande-Bretagne, Allemagne, États-Unis, URSS et Japon (période post-ware) | 1945-1960 | Large gamme de radars terrestres et maritimes ainsi que de petits systèmes aéroportés. |
| Grande-Bretagne, Allemagne, États-Unis, URSS, Japon, | 1960-1980 | Application dans l'aviation civile, la navigation maritime, mesure de vitesse des véhicules par la police, météorologie et même médecine. |
| États-Unis, Grande-Bretagne, Allemagne, Français, URSS, Japon, ... | 1980-2023 | Augmentation du traitement du signal due à la progression des calculateurs numériques. |



Figure 1. 2 Radar NEXRAD situé au centre d'opérations radar WSR-88D à Norman, Oklahoma

1. 2. 1 Applications

Le radar a été utilisé au sol, dans les airs, sur la mer et dans l'espace. Le radar au sol a été appliqué principalement à la détection, à la localisation et au suivi d'aéronefs ou de cibles spatiales. Le radar de bord est utilisé comme aide à la navigation et dispositif de sécurité pour localiser les bouées, le rivage lignes et autres navires, ainsi que pour l'observation des aéronefs. Le radar aéroporté peut être utilisé pour détecter d'autres aéronefs, navires ou véhicules terrestres, ou il peut être utilisé pour la cartographie des terres, l'évitement des tempêtes, l'évitement du terrain et la navigation. Dans l'espace, le radar a aidé au guidage des engins spatiaux et à la télédétection de la terre et de la mer. Le principal utilisateur du radar, et contributeur du coût de la quasi-totalité de son développement, a été l'armée: bien qu'il y ait eu des applications civiles de plus en plus importantes, principalement pour la navigation maritime et aérienne. Les domaines d'application civils et militaires du radar sont montrés par la [Table. 1. 2 \[13-16\]](#).

Table. 1. 2 Domaines d'applications du radar [13-16].

| Applications civiles | Applications militaires |
|--|--|
| <ul style="list-style-type: none"> - Contrôle du trafic aérien et gestion des vols. - Systèmes intelligents de gestion du trafic. - Approche et atterrissage des avions avec précision. - Gestion du trafic des navires (ports, voies navigables, détroits). - Navigation et évitement des collisions - Radar météo et surveillance des océans. - Surveillance au sol et alarmes anti-intrusion. - Sondage au sol et imagerie souterraine. - Capteurs de vitesse et altimètres du véhicule. - Surveillance étendue Multifonctions. | <ul style="list-style-type: none"> - Surveillance terrestre, océanique et aérienne. - Détection et poursuite des cibles. - Classification et identification balistique - Défense antimissile. - Alerte précoce aéroportée. - Contrôle de tir et guidage des missiles. - Emplacement du mortier et de l'artillerie. - Opérations de recherche et de sauvetage. - Sondage au sol et sous la surface. - Simulation et modélisation de détection Multifonctions. |

1. 3 Principe du radar

Selon les normes IEEE [13-16], un radar est un dispositif pour transmettre des signaux électromagnétiques et recevoir des échos d'objets d'intérêt (cibles) dans son volume de couverture comme montré par les **Figures. 1. 3 et 1. 4**. La présence d'une cible est révélée par détection de son écho ou de sa réponse par transpondeur. Des informations supplémentaires sur une cible fournies par un radar comprennent un ou plusieurs des éléments suivants: distance (portée), le temps écoulé entre la transmission du signal et la réception du signal de retour; la direction en utilisant des diagrammes d'antenne directive; le taux de changement de gamme, mesure du décalage Doppler; la description ou classification de la cible par analyse des échos et de leur variation dans le temps. La détection de cible est la capacité de distinguer la cible au niveau du récepteur. Le signal d'écho radar total au niveau du récepteur se compose de la cible (signal utile), du bruit (signal indésirable, non corrélé), de l'encombrement (échos indésirables mais corrélés provenant de cibles indésirables) et des

interférences (non intentionnelles telles que les signaux de radio et de télévision, et/ou des signaux de brouillage intentionnels).

La qualité de la détection dépend non seulement du matériau de la cible, de sa forme, mais aussi de la fréquence du signal émis. Les antennes des radars peuvent être fixes ou tournantes. Les radars eux-mêmes peuvent être mobiles lorsqu'ils sont embarqués sur des véhicules (terrestres, aériens ou maritimes).

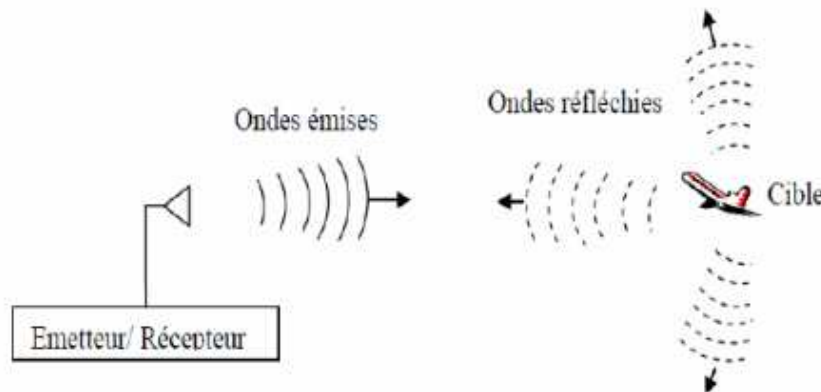


Figure 1. 3 Scénario illustrant le principe du radar.

I. 4 Types de radar

En fonction des informations qu'ils doivent fournir, les équipements radars utilisent des qualités et des technologies différentes. Ceci se traduit par une première classification des systèmes radars (voir Figure 1. 5)




Figure 1. 4 Détection des cibles maritimes par le radar.

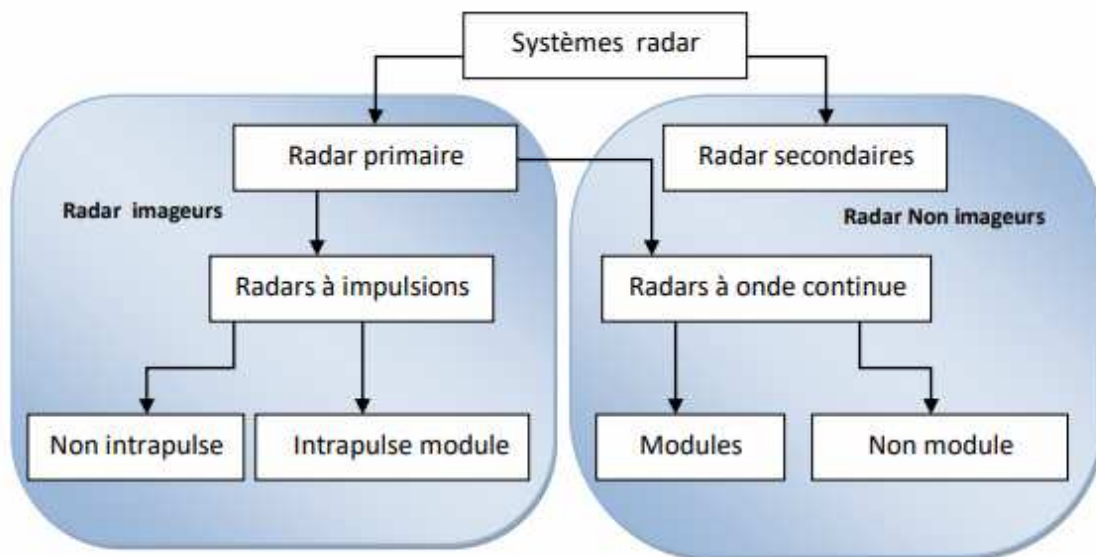


Figure 1. 5 Types de radars.

1. 4. 1 Radar primaire (ou imageurs)

Un radar primaire émet des signaux hyperfréquences qui sont réfléchis par les cibles. Les échos ainsi créés sont reçus et étudiés. Contrairement à un radar secondaire, un radar primaire reçoit la partie réfléchie de son propre signal. Les radars primaires peuvent être de type de deux dimensions (2D) donnant des mesures de distance et d'azimut ou trois dimensions (3D) avec une autre mesure complémentaire en angle de site (angle d'élévation dans le plan vertical). Pour les radars 2D, l'absence de toute mesure d'angle de site ne permet pas la discrimination en altitude. Ainsi, un avion comme un écho au sol ou un obstacle au sol dans le même azimut et à la même distance seront vus sans distinction. Sa fréquence varie entre 2.7 GHz et 3 GHz. On distingue deux types du radar primaire :

(i) Radars à impulsions : Les radars à impulsions émettent des impulsions de signal hyperfréquence à forte puissance, chaque impulsion est suivie d'un temps de silence plus long que l'impulsion elle-même, temps durant lequel les échos de cette impulsion peuvent être reçus avant qu'une nouvelle impulsion ne soit émise. La direction, la distance et parfois, si cela est nécessaire, hauteur ou altitude de la cible, peuvent être déterminées à partir des mesures de la position de l'antenne et du temps de propagation de l'impulsion émise. Les radars à onde continue génèrent un signal hyperfréquence continu. Le signal réfléchi est reçu et traité, mais le récepteur qui dispose de sa propre antenne n'est pas tenu d'être au même

emplacement que l'émetteur. Tout émetteur de station radio civile peut être simultanément utilisé comme un émetteur radar, pour peu qu'un récepteur relié à distance puisse comparer les temps de propagation du signal direct et du signal réfléchi. Des essais ont montré que la localisation d'un avion était possible par la comparaison et le traitement des signaux provenant de trois différentes stations émettrices.

(ii) Radars à onde continue : Le signal émis est constant en amplitude mais il est modulé en fréquence. Cette modulation rend à nouveau possible le principe de la mesure du temps de propagation. Ils sont spécialisés dans la mesure des vitesses et ils ne permettent pas à calculer les distances partielles. Ils sont employés par exemple par la gendarmerie pour les contrôles de vitesse sur les routes (cinémomètres radars). Un autre avantage non négligeable de ce type d'équipement est que, la réception n'étant jamais interrompue, les mesures s'effectuent en permanence. Ces radars sont utilisés lorsque les distances à mesurer ne sont pas trop grandes et qu'il est nécessaire d'effectuer des mesures ininterrompues (par exemple une mesure d'altitude pour un avion ou un profil de vents par un radar météorologique). Un principe similaire est utilisé par des radars à impulsions qui génèrent des impulsions trop longues pour bénéficier d'une bonne résolution en distance. Ces équipements modulent souvent le signal contenu dans l'impulsion afin d'améliorer leur résolution en distance. On parle alors de compression d'impulsion [1-4].

1. 4. 2 Radar secondaires

Avec ces radars, l'avion doit être équipé d'un transpondeur (transmetteur répondeur) qui répond à l'interrogation du radar en générant un signal codé. Cette réponse peut contenir beaucoup plus d'informations que celles qu'un radar primaire peut collecter (par exemple l'altitude, un code d'identification, ou encore un rapport de problème à bord comme une panne totale des radiocommunications) [1-4].

1. 5 Modèles de Swerling de cibles

Il y a pratiquement quatre modèles de Swerling qui décrivent les fluctuations de la cible [17]. Ce modèle exploite la pdf de Rayleigh. En fait, les quatre modèles de la cible découlent de la formule générale suivante:

$$p(s) = \frac{1}{\Gamma(k)} \frac{k}{2\sigma_s^2} \left(\frac{ks}{2\sigma_s^2} \right)^{k-1} \exp\left(-\frac{ks}{2\sigma_s^2} \right) \quad (1.1)$$

où $2\sigma_s^2$ est la puissance moyenne du signal reçu S . Le modèle de Swerling détermine la nature des fluctuations de la cible. En réalité, il y a deux types de cibles. Une cible rapidement fluctuante (pulse-to-pulse) et une cible lentement fluctuante (scan-to-scan). Il en découle quatre cas possibles:

Swerling I: Dans ce cas, la cible est lentement fluctuante (scan-to-scan), la pdf du signal cible suit la loi Exponentielle (le domaine d'intensité) donnée pour $k = 1$ est pris dans (1.1)

$$p(s) = \frac{1}{2\sigma_s^2} \exp\left(-\frac{s}{2\sigma_s^2}\right) \quad (1.2)$$

Swerling II: Dans ce cas, la cible est rapidement fluctuante (pulse-to-pulse), la pdf du signal cible est la même du cas de Swerling I (1.2). Ces deux types de modélisation peuvent caractérisés les statistiques des avions et des navires.

Swerling III: Pour ce cas, la cible est lentement fluctuante (scan-to-scan) mais la pdf du signal cible suit une loi non Exponentielle donnée pour $k = 2$ dans (1.1)

$$p(s) = \frac{4s}{(2\sigma_s^2)^2} \exp\left(-\frac{2s}{2\sigma_s^2}\right) \quad (1.3)$$

Swerling IV: Dans ce cas, la cible est rapidement fluctuante (pulse-to-pulse) et la pdf du signal cible est la même que le troisième modèle de Swerling. Ces deux derniers types de modélisation peuvent caractérisés les formes cylindriques et sphériques des cibles telles que les missiles.

1. 6 Modélisation du clutter

En général, dans les systèmes radar le clutter (bruit) est constitué des échos indésirables réfléchis par l'environnement. Ces échos peuvent perturber les opérations du radar et rendre la détection de la cible d'intérêt très difficile avec une augmentation du taux de fausse alarme. Le clutter peut être classé en deux catégories principales; à savoir le clutter de volume et le clutter de surface. La **Figure. 1. 6** présente le calcul de l'enveloppe des retours. Notant que le signal transmit est de la forme suivante [17]

$$q_e(t) = A \cos(\omega_c t) \quad (1.4)$$

où A (amplitude) et ω_c (fréquence intermédiaire) sont connus. L'écho reçu devient

$$q_r(t) = \tilde{A} \cos(\omega_c t + \tilde{\varphi}) \quad (1.5)$$

\tilde{A} et $\tilde{\varphi}$ sont des grandeurs aléatoires. L'amplitude reçue, $X = \tilde{A}$ est estimé après le calcul des deux composantes en-phase I et en quadrature Q , i.e., $X = \sqrt{I^2 + Q^2}$




Figure. 1. 6 Détecteur d'amplitude des echoes radar [17].

1. 6. 1 Clutter de volume

L'origine du clutter de volume est liée aux phénomènes atmosphériques. Ce type de clutter peut être produit par les insectes, les oiseaux, la pluie, la paille, la fumée, le vent sable, etc. Les échos des précipitations (pluie, neige, grêle, etc) créent du bruit dans les images radar. Ce constat a donné naissance aux premières techniques de brouillage et aux radars météorologiques [18]. La résolution en volume est approximée par

$$V_w \approx \frac{\pi}{8} \theta_a \theta_e R^2 c \tau \quad (1.6)$$

Où θ_e et θ_a sont respectivement les angles d'azimut et élévation, R est la portée, c la vitesse de la lumière et τ la période d'échantillonnage qui représente aussi la largeur d'impulsion. Ce type de bruit qui est Gaussien est modélisé par la loi Rayleigh ou la loi exponentielle.

$$\begin{cases} p(x) = \frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right), & \text{la loi Rayleigh} \\ p(x) = \frac{1}{2\sigma^2} \exp\left(-\frac{x}{2\sigma^2}\right), & \text{la loi exponentielle} \end{cases} \quad (1.7)$$

1. 6. 2 Clutter de surface

Le clutter de surface est généralement produit par les surfaces de la terre et de la mer. Le clutter de terre est plus difficile à modéliser car il dépend des propriétés diélectriques de la terre. De plus, il comprend les arbres, les végétations, le relief du terrain, les structures

artificielles, etc. La surface illuminée par l'onde émise usuellement appelée « empreinte radar » et elle est divisée en plusieurs surfaces élémentaires de dimension $(c\tau/2)\sec\psi_g$. Alors, la résolution en surface, A_c est exprimée par [19]

$$A_c \approx R\theta_{3dB} \frac{c\tau}{2} \sec\psi_g \quad (1.8)$$

où ψ_g est l'angle d'incidence (grazing angle) et $\sec(\psi_g) = 1/\cos(\psi_g)$. Ce type de clutter peut obéir plusieurs modèles statistiques donnés comme suit:

- **Distribution log-normal** : La distribution log-normal est caractérisée par une longue queue. Dans le but d'une détection CFAR robuste, ceci permet de modéliser le clutter de mer non-Gaussien [20]. La pdf de la distribution log-normal est donnée par :

$$p(x) = \frac{1}{\sigma\sqrt{2\pi x}} \exp\left(-\frac{(\ln(x)-\mu)^2}{2\sigma^2}\right) \quad (1.9)$$

où μ est la moyenne de $\ln(x)$ et σ^2 la variance.

- **Distribution Weibull** : La distribution Weibull a été utilisée pour modéliser le clutter de mer de haute résolution [21]. Cette distribution bi-paramétrique a une expression de la pdf donnée par:

$$p(x) = \frac{c}{b} \left(\frac{x}{b}\right)^{c-1} \exp\left(-\left(\frac{x}{b}\right)^c\right) \quad (1.10)$$

où b et c représentent les paramètres de forme et d'échelle, respectivement.

- **Distribution K** : La distribution K a été beaucoup utilisée par les radaristes pour décrire les variations du clutter de la mer ou du sol. Les résultats de plusieurs expériences prouvent évidemment que cette distribution donne une description convenable du clutter de la mer [22]. Elle est définie par deux composantes; la première est connue sous le nom de texture. Elle représente le niveau local moyen du clutter et suit la loi gamma. La deuxième, appelée speckle suit la loi Rayleigh.

$$\begin{cases} p(y) = \frac{2b^{2\nu} y^{2\nu-1}}{\Gamma(\nu)} \exp(-b^2 y^2) & \text{la texture} \\ p(x|y) = \frac{\pi x}{2y^2} \exp\left(-\frac{\pi x^2}{4y^2}\right) & \text{le speckle} \end{cases} \quad (1.11)$$

La pdf totale de la distribution K est obtenue en moyennant la composante speckle sur toutes les valeurs possibles de la composante texture comme suit :

$$\begin{aligned}
p(x) &= \int_0^{\infty} p(x|y)p(y)dy \\
&= \frac{4c}{\Gamma(\nu)} (cx)^\nu K_{\nu-1}(2cx)
\end{aligned} \tag{1.12}$$

où $K_{\nu-1}(2cx)$ est la fonction de Bessel modifiée, c est le paramètre d'échelle ($c = b\sqrt{\pi/4}$) et ν est le paramètre de forme and $\Gamma(\cdot)$ est la fonction gamma.

- **Distribution Pareto type II:** Ce modèle est obtenu pour une distribution inverse gamma de la composante texture, donnée par [23]

$$p(y) = \frac{1}{\beta^\alpha \Gamma(\alpha)} y^{-(\alpha+1)} \exp(-1/\beta y) \tag{1.13}$$

α est le paramètre de forme et β est le paramètre d'échelle. A la sortie du détecteur d'enveloppe la distribution Pareto type II est donnée par

$$p(x) = \frac{2x\beta\Gamma(\alpha+1)}{(\beta x^2 + 1)^{\alpha+1} \Gamma(\alpha)} \tag{1.14}$$

- **Distribution GC:** Pour assurer une bonne description des échos de la mer, le modèle GC (general compound) est considéré avec 5 paramètres [2].

$$\begin{cases}
p(x|y) = \frac{b_1}{y\Gamma(\nu_1)} \left(\frac{x}{y}\right)^{b_1\nu_1-1} \exp\left(-\left(\frac{x}{y}\right)^{b_1}\right) \\
p(y) = \frac{b_2}{y\Gamma(\nu_2)} \left(\frac{y}{a}\right)^{b_2\nu_2-1} \exp\left(-\left(\frac{y}{a}\right)^{b_2}\right)
\end{cases} \tag{1.15}$$

où a est le paramètre d'échelle, $\nu_{1,2}$ sont les paramètres de forme et $b_{1,2}$ sont les paramètres de puissance. A partir de (1.15), la distribution totale GC de l'enveloppe X est donnée par [9]

$$p(x) = \frac{b_1 b_2}{\Gamma(\nu_1)\Gamma(\nu_2)} \frac{x^{b_1\nu_1-1}}{a^{b_2\nu_2-1}} \int_0^{\infty} y^{b_2\nu_2 - b_1\nu_1 - 1} \exp\left(-\left(\frac{x}{y}\right)^{b_1} - \left(\frac{y}{a}\right)^{b_2}\right) dy \tag{1.16}$$

- **Distribution mixture:** Comme nous l'avons vu dans [24], de nombreux modèles ayant une distribution unique ne décrivent pas certains cas de données réelles qui suivent deux densités ou plus (p. ex., mélange de clutter Rayleigh et non-Rayleigh). Cela se produit lorsque des échos radar sont observés à partir de petites distances de cellules de portée. À cet effet, une distribution générale (une mixture de plusieurs distributions) pourrait être en mesure de décrire une majorité de scénarios de données réelles [25]

$$p(x) = \sum_{i=1}^n k_i p_i(x) \quad (1.17)$$

où $0 < k_i < 1$, $i = 1, \dots, n$ sont des probabilités et la pdf $p_i(x)$ peut prendre la forme d'une des distributions ci-dessus (c.-à-d., log-normal, Weibull, K, etc.) avec différentes valeurs de paramètres.

- **Distribution composite:** Afin de faire face à la modélisation des données de perte ou de données obéissant à la combinaison de deux distributions, les modèles composites ont été proposés par de nombreux chercheurs [26]. Comme le modèle de Pareto a une queue plus lourde que la distribution normale, les distributions telles que Exponentielle, log-normal, Weibull et gamma inverse ont été combinées avec la distribution de Pareto. Par exemple, la pdf du modèle gamma inverse composite et de Pareto est donnée par

$$p(x) = \begin{cases} cp_1(x) & 0 < x \leq \theta \\ cp_2(x) & \theta \leq x < +\infty \end{cases} \quad (1.18)$$

où

$$p_1(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{-\alpha-1} \exp(-\beta/x) \quad (1.19)$$

et

$$p_2(x) = \frac{a\theta^a}{x^{a+1}}, \quad x \geq \theta, a > 0, \theta > 0 \quad (1.20)$$

θ est une variable. Pour lisser la densité composite (1,18), on suppose que la pdf est continue et différentiable de θ . C'est-à-dire :

$$\begin{cases} p_1(\theta) = p_2(\theta) \\ \frac{dp_1(\theta)}{d\theta} = \frac{dp_2(\theta)}{d\theta} \end{cases} \quad (1.21)$$

Résoudre les équations ci-dessus simultanément et après de nombreuses manipulations algébriques, (1,18) devient

$$p(x) = \begin{cases} c \frac{(k\theta)^\alpha}{\Gamma(\alpha)} x^{-\alpha-1} \exp(-k\theta/x) & 0 < x \leq \theta \\ c \frac{(a-k)\theta^{a-k}}{x^{a-k+1}} & \theta \leq x < +\infty \end{cases} \quad (1.22)$$

Il résulte que, $a = \alpha - k = 0.1639$, $c = 0.7113$, $k = 0.1443$ et $\alpha = 0.3082$ sont des constants. Dans (1.22), nous avons seulement un seul paramètre d'être estimé, θ ou $\beta = k\theta$. Pour ce faire, les auteurs dans [26] proposent l'approche d'estimation Bayésienne.

1. 7 Conclusion

Dans ce premier chapitre, nous avons présenté en premier temps l'histoire et les applications modernes de l'équipement radar. Après, nous avons expliqué brièvement le principe de fonctionnement de radar à impulsions ainsi que les différents types de ce système à savoir les radars primaires et les radars secondaires. Puisque les cibles représentent des sources de signaux réfléchis aléatoires, les quatre modèles de Swerling ont été donnés représentant les fluctuations des surfaces équivalentes des avions, des navires, des missiles, etc. Enfin, nous avons évoqué les statistiques des échos indésirables (clutter) par des distributions gaussiennes et non-gaussiennes.

Chapitre 2

Modélisation du clutter par les lois CGIG et mixture CGIG

Sommaire du chapitre :

| | |
|---|----|
| 2. 1 Introduction..... | 19 |
| 2. 2 Modèles de clutter de mer avec ses estimateurs | 20 |
| 2. 3 Performances de la modélisation | 25 |
| 2. 4 Conclusion..... | 32 |

2. 1 Introduction

La modélisation statistique des distributions d'amplitude ou d'intensité des échos radar est d'une grande importance dans la communauté de recherche du traitement des signaux radar [29]. Pour les radars de surveillance maritime, on peut modéliser la puissance des échos de la mer de très faible résolution par la distribution exponentielle (ou Rayleigh pour le cas des amplitudes des échos). Toutefois, ce modèle est limité par certaines conditions de la surface de la mer et des paramètres du système radar. Néanmoins, ce modèle ne peut pas caractériser d'une manière rigoureuse les retours de la mer avec résolution spatiale plus élevée à faible angle d'incidence et à vitesse de vent élevée. Pour cette raison, une variété de fonctions de densité de probabilité (pdf) est proposée pour modéliser les échos de la mer radar avec des queues lourdes ou « spikiness » telles que les distributions gamma, log-normal,

Weibull, Gaussien-composé et général composé (GC) [2]. Ces deux derniers sont obtenus à partir de la combinaison de deux pdfs différentes représentant la composante speckle et la composante texture. Le speckle a une distribution exponentielle avec un paramètre de puissance aléatoire. La texture caractérise cette dernière et qui a une distribution gamma, gamma inverse, gaussien inverse ou log-normal [4]. Réellement, chaque distribution de la texture a une représentation spécifique d'échos marins à haute résolution. Nombreux schémas de détection de cibles CFAR non-cohérents et cohérents sont construits en fonction de ces modèles [17, 29]. L'étude de la modélisation exige l'estimation des paramètres du modèle théorique à partir d'un nombre fini d'échantillons de clutter. Après cette estimation, les seuils de détection CFAR sont formés en fonction des paramètres estimés pour prendre des décisions de présence des cibles avec des probabilités minimales de fausses alarmes. À partir de la littérature, nombreux estimateurs sont proposés. Parmi les estimateurs populaires utilisés dans les procédures de détection radar, nous citons la méthode MLE, la méthode des moments, la méthode du maximum a posteriori (MAP), la méthode d'estimation d'ajustement de courbe paramétrique (PCFE), la méthode de Bayes et la méthode de l'intelligence artificielle [24-26].

Dans ce chapitre, nous visons à obtenir un ajustement précis aux données de la mer IPIX (Intelligent Pixel X-band, [31]) en utilisant une distribution unique CGIG et une distribution mélangée CGIG. Pour évaluer les résultats de la modélisation, les modèles considérés sont comparés avec des distributions standard telles que Weibull, log-normal, Pareto type II et K . Pour ce faire, les paramètres de ses distributions sont estimés à partir d'un nombre fini d'échantillons de clutter de mer en utilisant la méthode MLE et la méthode LSA (Least Squares Approximation). L'étude expérimentale qui se suit montre que les modèles CGIG peuvent adapter avec une précision de nombreux scénarios de la base de données IPIX. Les différentes résolutions de cellules de portée, polarisations d'antennes et les numéros de cellules de portée sont pris en compte dans cette étude.

2. 2 Modèles de clutter de la mer avec ses estimateurs

Les cibles radar telles que les navires, les bateaux, les avions, etc., qui sont déplacés au-dessus de la surface de la mer sont détectées au moyen de modèles sélectionnés d'échos de la mer. Les distributions suivantes non-gaussiennes données dans le domaine d'intensité se sont avérées être des modèles efficaces pour ce type de clutter.

2. 2. 1 Distribution Weibull et la méthode MLE

La pdf de Weibull de la variable aléatoire, X est défini par deux paramètres; le paramètres de forme c et le paramètre l'échelle b [9]

$$p(x) = \frac{c}{2b^c} x_i^{c/2-1} \exp\left(-\frac{x_i^{c/2}}{b^c}\right) \quad (2.1)$$

soit x_1, x_2, \dots, x_N une séquence d'échantillons indépendants et distribués de façon identique (iid) d'une variable aléatoire X . La méthode MLE de c et b est donnée après la solution des dérivés partielles de la fonction de vraisemblance logarithmique [9]. Par conséquent

$$\frac{\sum_{i=1}^N x_i^{\hat{c}/2} \ln x_i^{1/2}}{\sum_{i=1}^N x_i^{\hat{c}/2}} - \frac{1}{N} \sum_{i=1}^N \ln x_i^{1/2} = \frac{1}{\hat{c}} \quad (2.2)$$

et

$$\hat{b} = \left(\frac{1}{N} \sum_{i=1}^N x_i^{\hat{c}/2} \right)^{\frac{1}{\hat{c}}} \quad (2.3)$$

Notant que l'équation (2.2) exige une solution numérique tandis que l'équation (2.3) a une forme analytique.

2. 2. 2 Distribution log-normal et la méthode MLE

La pdf log-normal peut également décrire les données de retours du sol ou de la mer à de faibles angles d'incidences (grazing angles) donnés par [27]

$$p(x) = \frac{1}{2\sigma\sqrt{2\pi}x} \exp\left(-\frac{(\ln(x)/2 - \mu)^2}{2\sigma^2}\right) \quad (2.4)$$

où μ est la moyenne de $\log(X)$ et σ est l'écart-type de $\log(X)$. La méthode MLE de μ et σ a une forme compacte et simplement donnée par [27]

$$\hat{\mu} = \frac{1}{N} \sum_{i=1}^N \log(x_i^{1/2}) \quad (2.5)$$

et

$$\hat{\sigma} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\log(x_i^{1/2}) - \hat{\mu})^2} \quad (2.6)$$

2. 2. 3 Distribution Pareto type II et la méthode MLE

La pdf de Pareto type II est obtenue lorsque la composante texture qui représente la fluctuation de la puissance du clutter suit le modèle gamma inverse. La description du clutter de la mer peut obéir à ce modèle comme [28]

$$p(x) = \frac{\alpha\beta^\alpha}{(x + \beta)^{\alpha+1}} \quad (2.7)$$

La méthode MLE correspondante du paramètre de forme α et du paramètre d'échelle β est donnée par [28]

$$\left(\frac{N}{\beta} - \sum_{i=1}^N \frac{1}{x_i + \beta} \right) \left(\frac{\sum_{i=1}^N \log(x_i - \hat{\beta})}{N} - \log(\hat{\beta}) \right)^{-1} \quad (2.8)$$

$$- \sum_{i=1}^N \frac{1}{x_i + \beta} = 0$$

et

$$\hat{\alpha} = \left(\frac{\sum_{i=1}^N \log(x_i - \hat{\beta})}{N} - \log(\hat{\beta}) \right)^{-1} \quad (2.9)$$

Aussi, cette approche impose des solutions numériques pour $\hat{\beta}$ (équation (2.8)) et pour $\hat{\alpha}$, nous avons une solution directe en fonction de $\hat{\beta}$ (équation (2.9)).

2. 2. 4 Distribution K et ses estimateurs

Le modèle K est une distribution populaire pour les données de la mer décorrelées. Elle a une forme gaussienne composée dont la distribution gamma décrit les variations de la puissance (la composante texture) donné par [29]

$$p(x) = \frac{2b^\nu}{\Gamma(\nu)} \left(\frac{x}{b} \right)^{\frac{\nu-1}{2}} K_{\nu-1}(2\sqrt{bx}) \quad (2.10)$$

Où $K_{\nu-1}(\cdot)$ est la fonction de Bessel modifiée de deuxième espèce d'ordre $\nu - 1$. La méthode compacte $\text{zlog}(z)$ du paramètre de forme ν est préférée donnée par [4, 29]

$$\hat{\nu} = \left(\frac{\sum_{i=1}^N x_i \log(x_i)}{\sum_{i=1}^N x_i} - \frac{1}{N} \sum_{i=1}^N \log(x_i) - 1 \right)^{-1} \quad (2.11)$$

Le paramètre d'échelle b est estimé directement par

$$\hat{b} = \frac{\hat{\nu}}{\frac{1}{N} \sum_{i=1}^N x_i} \quad (2.12)$$

La procédure MLE peut également être utilisée, mais les estimés sont calculés numériquement à l'aide de la fonction de vraisemblance (LF) suivante :

$$LF = \prod_{i=1}^N \frac{2b^\nu}{\Gamma(\nu)} \left(\frac{x_i}{b} \right)^{\frac{\nu-1}{2}} K_{\nu-1}(2\sqrt{bx_i}) \quad (2.13)$$

A partir de (2.13), le log-LF (LLF) correspondant est donné par

$$LLF = \sum_{i=1}^N \log \left(\frac{2b^\nu}{\Gamma(\nu)} \left(\frac{x_i}{b} \right)^{\frac{\nu-1}{2}} K_{\nu-1}(2\sqrt{bx_i}) \right) \quad (2.14)$$

Alors, la méthode MLE de ν est obtenue après l'optimisation de l'équation non-linéaire suivante :

$$\hat{\nu} = \arg \min_{\nu > 0} \left[- \sum_{i=1}^N \log \left(\frac{2\nu^\nu}{\left(\frac{1}{N} \sum_{i=1}^N x_i \right)^\nu \Gamma(\nu)} \left(\frac{x_i}{N\nu \sum_{i=1}^N x_i} \right)^{\frac{\nu-1}{2}} K_{\nu-1} \left(2 \sqrt{\frac{N\nu x_i}{\sum_{i=1}^N x_i}} \right) \right) \right] \quad (2.15)$$

et

$$\hat{b} = \frac{\hat{\nu}}{\frac{1}{N} \sum_{i=1}^N x_i} \quad (2.16)$$

2. 2. 5 Distribution CGIG et la méthode MLE

À partir de [30], il a été montré que le modèle CGIG avec deux paramètres peut fournir une bonne qualité d'ajustement aux données IPIX réelles. Ici, le modèle gaussien inverse est utilisé pour décrire les statistiques de la composante texture [4, 30].

$$p(x) = \left(\frac{\sqrt{\lambda}}{(\lambda + 2x)^{3/2}} + \frac{\lambda}{\mu(\lambda + 2x)} \right) \exp \left(\frac{\lambda}{\mu} \left(1 - \sqrt{1 + \frac{2x}{\lambda}} \right) \right) \quad (2.17)$$

Où λ est le paramètre de forme et μ est la moyenne de X . Notant que, λ dépend de l'état de la surface de la mer ainsi que les paramètres radar (fréquence de propagation, longueur d'onde, etc). Pour les échos de la mer à haute résolution, les valeurs de λ sont typiquement comprises entre 0.1 et $+\infty$, tandis que le clutter pointu correspond aux valeurs de $\lambda \in [0.1, 1]$ et la distribution exponentielle est atteinte pour $\lambda \rightarrow +\infty$. L'approche MLE pour λ est donnée par [4]

$$\hat{\lambda} = \arg \min_{\lambda \in [0, +\infty]} \left(- \sum_{i=1}^M \log \left(\sqrt{\frac{\lambda}{2\pi}} \frac{e^{\lambda N / \langle x \rangle} x_i^{N-1}}{\Gamma(N)} 2 \left(\frac{\langle x \rangle^2 (\lambda + 2x_i)}{\lambda N^2} \right)^{-\frac{2N+1}{4}} \right. \right. \\ \left. \left. K_{-N-1/2} \left(\frac{N\lambda}{\langle x \rangle} \sqrt{1 + \frac{2x_i}{\lambda}} \right) \right) \right) \quad (2.18)$$

avec

$$\hat{\mu} = \langle x \rangle / N \quad (2.19)$$

2. 2. 6 Distribution CGIG mixture et la méthode LSA

En réalité, de nombreux modèles à distribution unique ne correspondent pas à certains cas de données réelles qui suivent deux densités ou plus. Cela se produit lorsque les échos radar sont observés à partir de petites cellules de portée (résolution élevée). À cet effet, la distribution CGIG mixture est proposée pour décrire la majorité de scénarios de données. Le modèle mixture CGIG général est donné en fonction de (2.17) [25]

$$p(x) = \sum_{i=1}^n k_i p_i(x) \quad (2.20)$$

où k_i , $i = 1, \dots, n$ est la probabilité et n le nombre de distributions CGIG. (2.20) a un nombre de paramètres égale à $3n-1$ avec n paramètres d'échelle discrète, n paramètres de forme

discrète et $n-1$ probabilités k_i . En raison de la complexité de l'approche MLE de (2.20), la technique d'ajustement de courbe (PCFE) est la plus appropriée pour estimer simultanément tous les paramètres du modèle. L'organigramme de l'algorithme de Nelder-Mead donné dans [25] est appliqué ici pour estimer les paramètres d'après la fonction objective des CCDFs de CGIG mixture suivante (somme des erreurs au carré)

$$Fitness_{CCDF} = \sum_{i=1}^m [real_{CCDF}(T_i) - theor_{CCDF}(T_i)]^2 \quad (2.21)$$

A condition que $\lambda_i > 0$, $\mu_i > 0$ pour $i = 1, 2$ et $k_1 + k_2 = 1$. m désigne le nombre de points utilisés dans les courbes de la fonction objectif. La CCDF théorique est donné par

$$theor_{CCDF}(T_i) = 1 - \left(1 + \frac{2T_i}{\lambda}\right)^{-1/2} \exp\left(\frac{\lambda}{\mu} \left(1 - \sqrt{1 + \frac{2T_i}{\lambda}}\right)\right) \quad (2.22)$$

Où T_i représente le seuil normalisé.

2. 3 Performances de la modélisation

Dans cette section, l'évaluation de la modélisation des distributions ci-dessus est réalisée au moyen de la base de données IPIX disponible. Les estimateurs MLE et LSA correspondants sont exécutés pour obtenir les estimations des paramètres de forme et d'échelle de chaque modèle. Les courbes CCDF résultantes sont comparées ensemble avec les CCDF empiriques afin de confirmer le meilleur ajustement du modèle théorique.

La base de données du radar IPIX de McMaster est disponible avec différents paramètres maritimes et radar [31]. Il est destiné aux chercheurs pour évaluer leurs algorithmes développés dans la communauté de recherche radar. Le système radar IPIX est un radar entièrement cohérent en bande-X avec polarisation double antenne d'émission/réception, agilité de fréquence et mode d'observation/surveillance. Les données IPIX utilisées dans ce mémoire concernent les mesures à haute résolution recueillies à Grimsby durant l'hiver 1998, sur la rive du lac Ontario. L'affichage graphique de tous les 222 ensembles de données et images, y compris les tracés de retour radar et les spectres Doppler temporels, est disponible dans [31]. Plus précisément, il y a co-polarisations, HH et VV (Lpol), et polarisations croisées, HV et VH (Xpol), réception cohérente, conduisant à un quadruplet des valeurs I et Q pour co-pol et cross-pol. Grâce aux enregistrements, le radar émettait avec un PRF de 1000 Hz et une longueur d'impulsion de 0,06 us. Les données IPIX reçues sont traitées et enregistrées dans des matrices de dimensions (60000x34) où 34

indique le nombre de cellules de portée et 60000 le nombre d'impulsions. Dans cette section, nous concentrons notre analyse sur les ensembles de données 84, 85 et 86 qui correspondent aux résolutions de portée 30m, 15m et 3m respectivement. De plus amples détails et caractéristiques des ensembles de données IPIX sont précisés dans [31].

Pour le cas de haute résolution de 3m, polarisation HH et cellule de 17^{ème} gamme, **Figure. 2. 1** montre le meilleur ajustement à CCDF réel à travers le modèle CGIG mixture. Ce dernier a 5 paramètres à optimiser, mais la dimension de recherche est réduite à 4 paramètres, puisque le moment de premier ordre est utilisé lors de l'optimisation LSA via l'algorithme de Nelder-Mead. Cette amélioration par rapport aux distributions uniques est due aux données qui ont un mélange de clutter gaussien et non-gaussien. Lorsque la cellule de portée est changée à 5, la **Figure. 2. 2** illustre les performances de modélisation du mélange et de la distribution standard. On observe immédiatement que les modèles Weibull, K , Pareto, CGIG et CGIG mixture ont la même approximation des données empiriques.

Pour la polarisation de l'antenne radar VV, le modèle CGIG mixture garantit la meilleure adaptation aux données réelles comme le montre dans la **Figure. 2. 3**. Pour une résolution de 15m, polarisation HH et cellule numéro 23, on remarque que le modèle CGIG fournit une qualité d'ajustement aux données réelles (voir **Figure. 2. 4**). Si une polarisation VV, une résolution de 15m et la cellule 8 sont prises en compte, les échos marins illustrés à la **Figure. 2. 5** sont bien rapprochés aux modèles K , CGIG et CGIG mixture.

Les courbes des CCDF obtenues à partir de la polarisation HH, résolution 30m et cellule 25 sont mises en évidence par la **Figure. 2. 6**. En outre, le modèle CGIG et le modèle CGIG mixture maintiennent la meilleure erreur d'ajustement par rapport aux autres modèles. La **Figure. 2. 7** illustre les courbes des CCDF ajustées qui sont bien approximatives lorsque les modèles CGIG, CGIG mixture et Pareto type II sont utilisés dans le cas de la polarisation VV, résolution 30m et cellule 7.

La **Figure. 2. 8** représente les performances de modélisation des données de la mer à partir du fichier nommé « 19931118_162155_stareC0000.cdf ». Dans ce cas, la polarisation de l'antenne peut avoir HV ou VH. Les détails de ce fichier sont donnés dans la **Table 2. 1**. Pour une polarisation VH et la 12^{ème} cellule, on remarque que les modèles CGIG et log-normal ont une bonne régression de la queue de la CCDF réelles. Pour une polarisation HV et en prenant la même cellule de résolution, on observe dans la **Figure. 2. 9** que les queues des modèles CGIG, log-normal, Pareto type II et mixture CGIG se rapprochent vers la queue de la

CCDF empirique. D'après les résultats de la modélisation présentés dans cette section, il est clair que la modélisation devient très difficile pour une polarisation de l'antenne HV ou VH. Pour des polarisations HH et VV, la complication de la modélisation diminue par l'utilisation des distributions CGIG et mixture CGIG.

Table 2. 1 Détails techniques du fichier « 19931118_162155_stareC0000.cdf »

```

%% Variables:
  RF_frequency = 9.39 GHz
  Pulse_length = 200 nanoseconds
  PRF = 1000 Hertz
  Unambig_velocity = 7.9872 metres per second
  range = [2649 2664 ..nrange.. 2844] metres
  azimuth_angle = [170.2386 170.2386 ..nsweep.. 170.2332] degrees
  elevation_angle = [359.5441 359.5441 ..nsweep.. 359.5496] degrees
  radar_lat = 44.62 degrees
  radar_lon = 63.43 degrees
  radar_elev = 30 metres
  antenna_beamwidth = 0.9 degrees
  antenna_gain = 45.7 dB
  like_stc_RF = 0 volts
  cross_stc_RF = 0 volts
  like_stc_IF = 0.84961 volts
  cross_stc_IF = 0.84961 volts
  decimation = 1 none
  adc_like_I = 0
  adc_like_Q = 1
  adc_cross_I = 2
  adc_cross_Q = 3
  adc_data = [nsweep x ntxpol x nrange x nadc] ADC output

%% Dimensions:
  nsweep = 131072
  ntxpol = 2
  nrange = 14
  nadc = 4

%% Global attributes:
  Organization = McMaster University
  Instrument_name = IPIX X-band Polarimetric Coherent Radar
  Campaign = OHGR - Dartmouth
  Site = Osborne Head, NS
  Data_collection_date = 1993/11/18 16:21:55
  TX_polarization = A
  NetCDF_file_name = 19931118_162155_stareC0000.cdf
  NetCDF_creation_routine = make_Dartmouth_ncdf
  NetCDF_creation_date = Thu May 17 20:02:00 2001
  Field_CD_name = ohgr0022
  Field_file_dir = Nov1893a
  Field_file_name = stareC7536397150_0000
  Field_dataset_name = /data/Nov18/stareC0

```




Figure. 2. 1 Illustration de la modélisation pour la polarisation HH, résolution 3 m et la 17^{ème} cellule de portée.




Figure. 2. 2 Illustration de la modélisation pour la polarisation HH, résolution 3 m et la 5^{ème} cellule de portée.




Figure. 2. 3 Illustration de la modélisation pour la polarisation VV, résolution 3 m et la 13^{ème} cellule de portée.

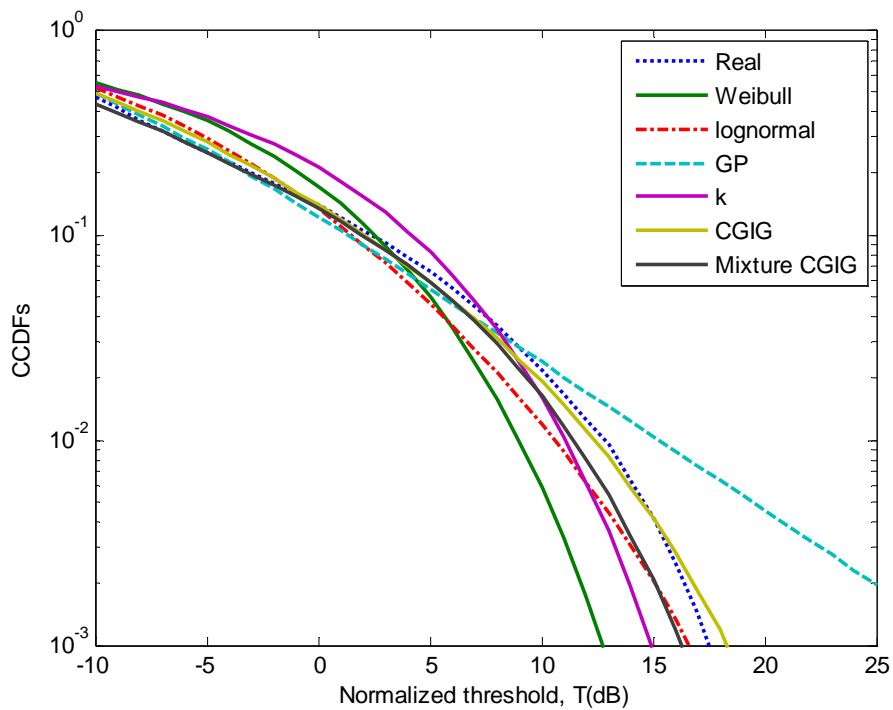


Figure. 2. 4 Illustration de la modélisation pour la polarisation HH, résolution 15 m et la 23^{ème} cellule de portée.




Figure. 2. 5 Illustration de la modélisation pour la polarisation VV, résolution 15 m et la 8^{ème} cellule de portée.




Figure. 2. 6 Illustration de la modélisation pour la polarisation HH, résolution 30 m et la 25^{ème} cellule de portée.

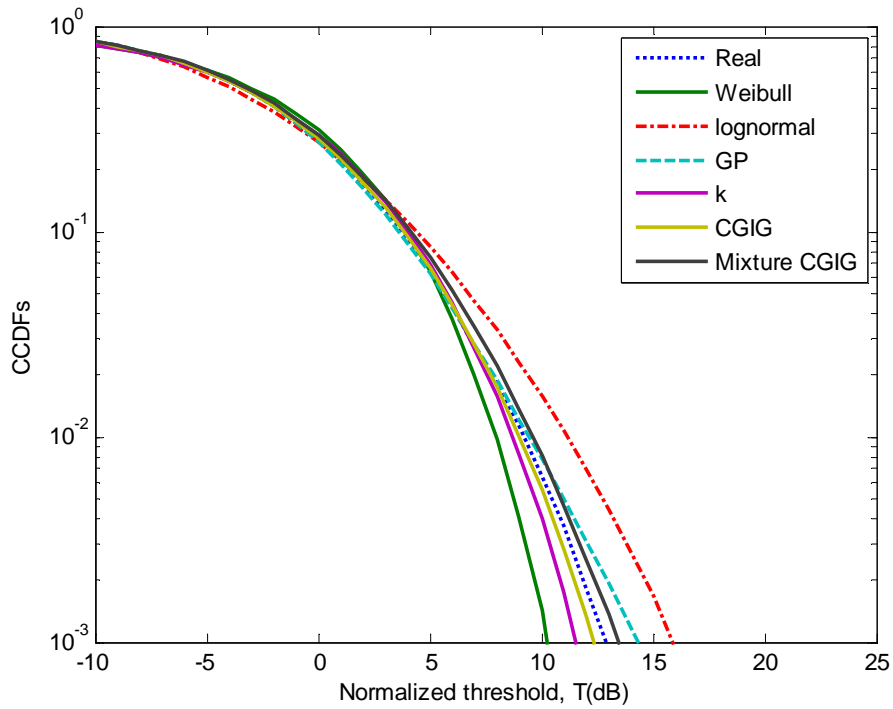


Figure. 2. 7 Illustration de la modélisation pour la polarisation VV, résolution 30 m et la 7^{ème} cellule de portée.




Figure. 2. 8 Illustration de la modélisation pour la polarisation VH, et 12^{ème} cellule de portée.




Figure. 2. 9 Illustration de la modélisation pour la polarisation HV, et 12^{ème} cellule de portée.

2. 4 Conclusion

Dans ce chapitre, la modélisation du clutter marin basée sur l'utilisation de la base de données IPIX a été étudiée et analysée. Pour ce faire, des modèles non-gaussiens ont été considérés tels que Weibull, log-normal, K , Pareto type II, CGIG et mixture CGIG. Les estimateurs MLE et LSA ont été appliqués pour obtenir les paramètres des modèles en question à partir des échantillons de la surface de la mer. Plusieurs scènes de données réelles IPIX enregistrées en fonction des paramètres radar comme la polarisation de l'antenne HH, VV, VH ou HV, résolution de cellules 3m, 15m ou 30m et différentes cellules de portée ont été prises en compte pour évaluer les performances de modélisation des distributions ci-dessus. Il était bien conclu que les modèles CGIG et mixture CGIG sont les plus adaptés pour la plus part des cas.

Chapitre 3

Estimation des paramètres de la distribution CGIG basée sur le ANN

Sommaire du chapitre :

| | |
|--|----|
| 3. 1 Introduction..... | 33 |
| 3. 2 Méthodes d'estimation existante..... | 34 |
| 3. 3 Estimation par le ANN | 36 |
| 3. 4 Comparaison des résultats d'estimation..... | 43 |
| 3. 5 Conclusion..... | 52 |

3. 1 Introduction

L'estimation des paramètres pour les modèles gaussiens composés est l'une des questions les plus considérées dans le domaine de traitement de signaux radar. Pour un bruit thermique négligeable, un certain nombre d'estimateurs compacts avec différents degrés de précision sont proposés pour le calcul des paramètres des distributions log-normal, K , Pareto type II et CGIG [4, 9]. Les méthodes basées sur les moments d'ordres supérieurs, fractionnaires et logarithmique (i.e., $\text{zlog}(z)$) sont trouvées d'être efficaces pour la prédiction des paramètres de la distribution K à partir des échos radar [23]. Notant que l'approche $\text{zlog}(z)$ se converge vers l'approche MLE mais cette dernière impose des calculs numériques pour le paramètre de forme. Ce genre de méthodes sont aussi développées pour les cas des distributions Pareto type II et CGIG [4, 28]. En se basant sur les moments fractionnaires et logarithmiques, la méthode d'interpolation est trouvée pour estimer le paramètre de forme de la

distribution CGIG [19]. Cependant, l'approche MLE pour ce modèle est donnée en fonction de la minimisation du logarithme de la fonction de vraisemblance négative. En ce qui concerne la détection CFAR dans un clutter CGIG distribué, la procédure GLRT-CFAR est seulement prise en compte dans la littérature [32].

Le présent chapitre est structuré comme suit. Dans la Section 3. 2, nous rappelons les méthodes d'estimation des moments d'ordres entiers, fractionnaires, $\text{zlog}(z)$ et MLE. Dans la Section 3. 3, nous décrivons l'architecture des réseaux de neurones utilisée pour la prédiction des valeurs du paramètre de forme de la distribution CGIG. Dans la Section 3. 4, nous présentons au moyen de simulations Monte-Carlo une série de comparaisons de l'estimation par les approches $\text{zlog}(z)$, MLE et ANN. Enfin, une conclusion est présentée dans la Section 3. 5.

3. 2 Méthodes d'estimation existantes

L'estimation des paramètres est une tâche très essentielle pour l'analyse des échos de la mer modélisée par la distribution CGIG. Dans le cas d'une transmission d'une seule impulsion, on va résumer par la suite, les formules explicites des approches d'estimation existantes. A partir de (2.17), la P_{FA} a la forme suivante [4]

$$P_{FA} = \left(1 + \frac{2T}{\lambda}\right)^{-1/2} \exp\left(\frac{\lambda}{\mu} \left(1 - \sqrt{1 + \frac{2T}{\lambda}}\right)\right) \quad (3.1)$$

Où T est le seuil de détection normalisé.

3. 2. 1 Méthode des moments entiers

Après l'obtention de N échantillons de clutter CGIG non-corrélés, i.e., $x_i, i = 1, \dots, N$ de la variable aléatoire d'intensité X , cette approche d'estimation est simplement obtenue par [19]

$$\begin{cases} \hat{\lambda} = \langle x \rangle \left(\frac{\langle x^2 \rangle}{2\langle x \rangle^2} - 1 \right)^{-1} \\ \hat{\mu} = \langle x \rangle \end{cases} \quad (3.2)$$

A condition que, $\frac{\langle x^2 \rangle}{2\langle x \rangle^2} > 1$ et $\langle x \rangle \neq 0$. $\langle \cdot \rangle$ désigne le moment empirique (i.e.,

$$\langle x^r \rangle = \frac{1}{N} \sum_{i=1}^N x_i^r).$$

3. 2. 2 Méthode des moments fractionnaires

Cette approche d'estimation est basée sur le calcul des moments d'ordres fractionnaires. Elle est exprimée en fonction de la fonction de Bessel [19]

$$\hat{A} = \sqrt{\hat{\theta}} e^{\hat{\theta}} K_{r-1/2}(\hat{\theta}) \quad (3.3)$$

Avec $\hat{\theta} = \hat{\lambda} / \hat{\mu}$ et $\hat{A} = \frac{\langle x^r \rangle}{\langle x \rangle^r \Gamma(1+r)} \sqrt{\frac{\pi}{2}}$. Une fois le paramètre $\hat{\theta}$ est obtenu par (3.3) à l'aide

de la méthode numérique d'interpolation, $\hat{\mu} = \langle x \rangle$ et $\hat{\lambda} = \hat{\mu} \hat{\theta}$. Il est mentionné dans [17] que

la partie droite de l'équation (3.3) possède une nature monotone croissante en fonction de θ .

3. 2. 3 Méthode zlog(z)

Cette approche d'estimation est exprimée en fonction de la fonction intégrale exponentielle, E_i suivante [19]

$$\frac{\langle x \log(x) \rangle}{\langle x \rangle} - \langle \log(x) \rangle - 1 = -2e^{2\hat{\lambda}/\hat{\mu}} E_i(-2\hat{\lambda}/\hat{\mu}) \quad (3.4)$$

Aussi, si on prend $\hat{\theta} = \hat{\lambda} / \hat{\mu}$, (3.4) est réduit à un seul degré de liberté et peut être exprimé en termes de la fonction hypergéométrique généralisée, ${}_2F_0(\cdot, \cdot; \cdot; \cdot)$. D'où

$$\hat{B} = 2\hat{\theta} {}_2F_0(1, 1; \cdot; -\hat{\theta}) \quad (3.5)$$

où \hat{B} est la partie gauche de (3.5). En outre, le côté droit de (3.5) est strictement monotone d'une manière décroissante en fonction de θ dont la méthode de 'splines' (i.e., interpolation) est une bonne approximation pour obtenir les valeurs de $\hat{\theta}$ avec $\hat{\mu} = \langle x \rangle$ et $\hat{\lambda} = \hat{\mu} \hat{\theta}$.

3. 2. 4 Méthode MLE

Il est mentionné dans le Chapitre 2 que l'estimation ML des paramètres est une méthode efficace lorsque la forme de la distribution statistique du clutter à estimer est connue et n'est pas compliquée mathématiquement. La méthode MLE est alors basée sur l'évaluation de la fonction de vraisemblance de la distribution IG-CG donnée par (2.17) [19]. D'où

$$p(x; \lambda, \mu) = \prod_{i=1}^N \left(\frac{\sqrt{\lambda}}{(\lambda + 2x_i)^{3/2}} + \frac{\lambda}{\mu(\lambda + 2x_i)} \right) \exp \left(\frac{\lambda}{\mu} \left(1 - \sqrt{1 + \frac{2x_i}{\lambda}} \right) \right) \quad (3.6)$$

Le logarithme de (3.6) devient

$$\log(p(x; \lambda, \mu)) = \sum_{i=1}^N \left[\log \left(\frac{\sqrt{\lambda}}{(\lambda + 2x_i)^{3/2}} + \frac{\lambda}{\mu(\lambda + 2x_i)} \right) + \frac{\lambda}{\mu} - \frac{1}{\mu} \sqrt{\lambda^2 + 2\lambda x_i} \right] \quad (3.7)$$

Afin de trouver le maximum de la fonction de vraisemblance, nous calculons ses dérivés partiels par rapport à λ et μ et les laissons égaux à zéro. Après quelques étapes de dérivés de (3.7), nous obtenons

$$\frac{\partial \log(p(x; \lambda, \mu))}{\partial \lambda} = \frac{N}{\hat{\mu}} - \sum_{i=1}^N \left(\frac{1}{\hat{\lambda} + 2x_i} + \frac{\hat{\lambda} + x_i}{\hat{\mu} \sqrt{\hat{\lambda}^2 + 2\hat{\lambda}x_i}} - \frac{\hat{\mu}x_i + \sqrt{\hat{\lambda}(\hat{\lambda} + 2x_i)^{3/2}}}{\sqrt{\hat{\lambda}(\hat{\lambda} + 2x_i)} (\hat{\mu} \sqrt{\hat{\lambda}} + \hat{\lambda} \sqrt{\hat{\lambda} + 2x_i})} \right) = 0 \quad (3.8)$$

et

$$\frac{\partial \log(p(x; \lambda, \mu))}{\partial \mu} = N - \sum_{i=1}^N \frac{\hat{\lambda} + 2x_i}{\hat{\mu} + \sqrt{\hat{\lambda}^2 + 2\hat{\lambda}x_i}} = 0 \quad (3.9)$$

Il est à noter que la méthode ML donnée par (3.8) et (3.9) ne contient aucune solution analytique. Des méthodes numériques doivent être utilisées pour résoudre ces équations. Vraiment, il n'est pas facile d'avoir des solutions précises et convergentes, surtout si le nombre d'échantillons, N est faible. Comme alternative, la complexité de la méthode MLE est réduite en une seule dimension de recherche par l'utilisation du moment d'ordre 1 dans l'équation (3.8) (voir Chapitre 2).

3. 3 Estimation par le ANN

Dans cette section, on va donner quelques détails sur le réseau de neurones artificiels (ANN) classique et le ANN à apprentissage profond (Deep-learning : DL) et puis on va spécifier l'architecture du ANN utilisé comme estimateur du paramètre de forme du clutter CGIG distribué.

3. 3. 1 Généralités sur le ANN

Les réseaux neuronaux sont composés d'éléments simples fonctionnant en parallèle. Ces éléments sont inspirés des systèmes nerveux biologiques, et qui par la suite s'est

rapproché des méthodes statistiques. Les ANNs sont généralement optimisés par des méthodes d'apprentissage de type probabiliste, en particulier Bayésien. Ils sont placés d'une part dans la famille des applications statistiques, qu'ils enrichissent avec un ensemble de paradigmes permettant de créer des classifications rapides (réseaux de Kohonen en particulier), et d'autre part dans la famille des méthodes de l'intelligence artificielle auxquelles ils fournissent un mécanisme perceptif indépendant des idées propres de l'implémenteur, et des informations d'entrée au raisonnement logique formel. En modélisation des circuits biologiques, ils permettent de tester quelques hypothèses fonctionnelles issues de la neurophysiologie, ou encore les conséquences de ces hypothèses pour les comparer au réel [33].

Aujourd'hui, les réseaux neuronaux peuvent résoudre des problèmes de l'ingénierie qui ne pouvaient pas être abordés auparavant de manière pratique. Ils ont été formés pour exécuter des fonctions complexes dans divers domaines, y compris la reconnaissance des formes, l'identification, la classification, la parole, la vision et les systèmes de contrôle. Les réseaux neuronaux peuvent également être formés pour résoudre des problèmes difficiles pour les ordinateurs conventionnels ou les êtres humains.

Parmi les types des réseaux de neurones, on trouve les réseaux en couches comme montré par la **Figure. 3. 1**. Le modèle de neurone et l'architecture d'un réseau neuronal décrivent comment un réseau transforme son entrée en sortie. Cette transformation peut être considérée comme un calcul. L'influx d'information va toujours des couches d'entrées aux couches de sorties. Comme dans la nature, les connexions entre les éléments déterminent en grande partie la fonction réseau. On peut entraîner un réseau neuronal à exécuter une fonction particulière en ajustant les valeurs des connexions (poids) entre les éléments [34].

Typiquement, les réseaux neuronaux sont ajustés, ou formés, de sorte qu'une entrée particulière mène à une sortie cible spécifique. La **Figure. 3. 2** illustre une telle situation. Là, le réseau est ajusté, basé sur une comparaison de la sortie et de la cible, jusqu'à ce que la sortie réseau corresponde à la cible. En général, de nombreuses paires d'entrées/cibles sont nécessaires pour former un réseau. Ces réseaux peuvent être appris par l'algorithme de la descente de gradient. Ils sont adaptés aux données de tailles fixes, comme des images. Ils portent le nom de perceptron multicouche (PMC), Feed-Forward ou Multi Layer Perceptron (MLP) en anglais.

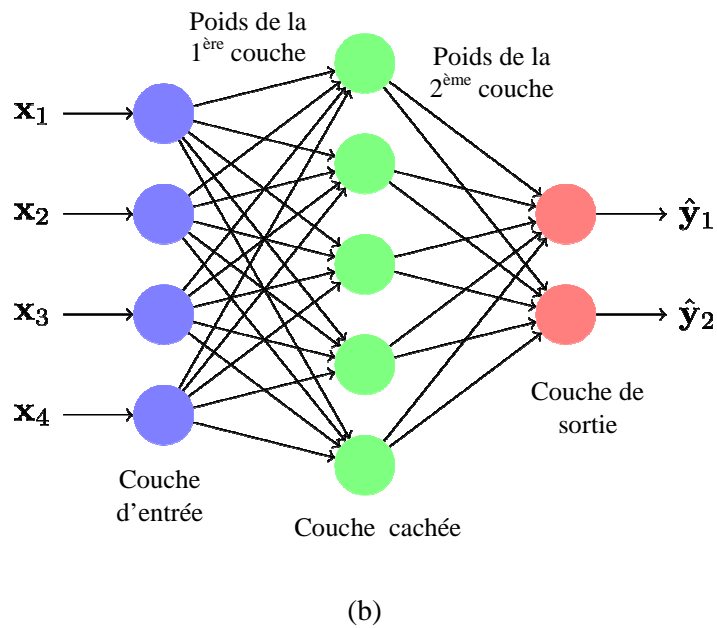
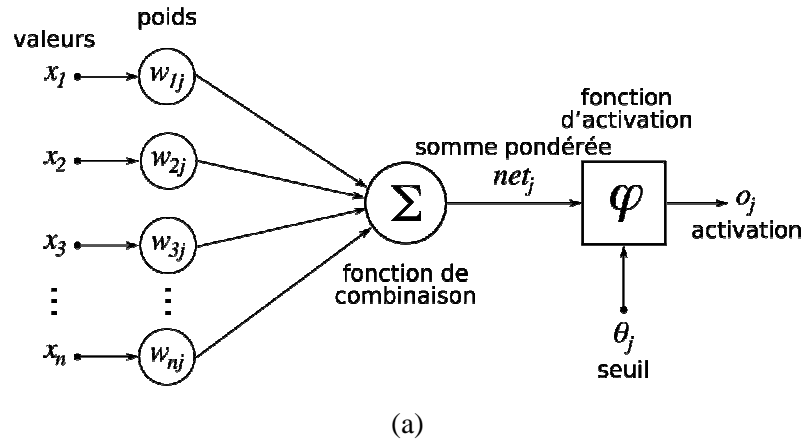


Figure. 3. 1 Structure du réseau de neurones non-récurrent.

(a) Neurone formel.

(b) Réseau de neurone organisé en couches.

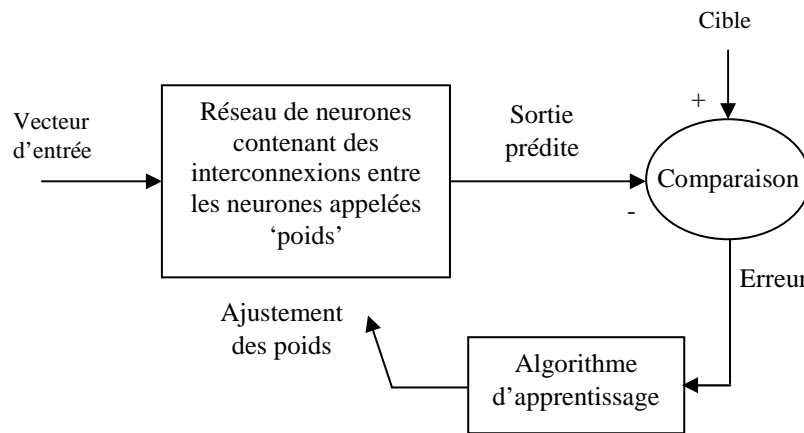


Figure. 3. 2 Entraînement du réseau de neurone non-récurrent.

3. 3. 2 Réseau de neurones à apprentissage profond (DL)

Comme expliqué précédemment, les réseaux neuronaux combinent plusieurs couches de traitement non-linéaires, utilisant des éléments simples fonctionnant en parallèle. Les modèles de DL peuvent atteindre une précision de pointe dans la classification des objets, dépassant parfois le rendement au niveau humain [35].

En d'autres mots, le DL est une classe d'apprentissage automatique qui fonctionne beaucoup mieux sur les données non-structurées. Les techniques d'apprentissage profond surpassent les techniques d'apprentissage automatique actuelles. Il permet aux modèles informatiques d'apprendre progressivement des fonctionnalités à partir de données à plusieurs niveaux. La popularité de DL a amplifié que la quantité de données disponibles a augmenté ainsi que l'avancement du matériel qui fournit des ordinateurs puissants [36]. Bien que le DL ait été théorisé pour la première fois dans les années 1980, il y a deux raisons principales pour lesquelles il n'est devenu utile que récemment :

- Le DL nécessite de grandes quantités de données étiquetées. Par exemple, le développement automobile sans conducteur nécessite des millions d'images et des milliers d'heures de vidéo.
- Le DL exige aussi une puissance de calcul substantielle. Les CPU haute performance ont une architecture parallèle efficace pour l'apprentissage profond.

Les applications de DL sont essentiellement utilisées dans des domaines différents suivants :

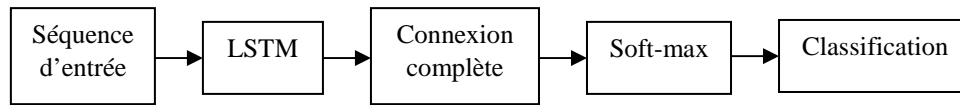
- **Conduite automatisée** : Les chercheurs en automobile utilisent le DL pour détecter automatiquement des objets tels que les panneaux d'arrêt et les feux de signalisation. De plus, l'apprentissage en profondeur est utilisé pour détecter les piétons, ce qui contribue à réduire les accidents.
- **Aérospatiale et défense** : Le DL est utilisé pour identifier les objets des satellites qui localisent les zones d'intérêt, et identifier les zones sûres ou dangereuses pour les troupes.
- **Recherche médicale** : Les chercheurs en oncologie utilisent l'apprentissage profond pour détecter automatiquement les cellules cancéreuses. Les équipes de l'UCLA ont construit un microscope avancé qui produit un ensemble de données de grande dimension utilisé pour former une application d'apprentissage profond pour identifier avec précision les cellules cancéreuses.
- **Automatisation industrielle** : Le DL aide à améliorer la sécurité des travailleurs autour des machines lourdes en détectant automatiquement les personnes ou les objets qui se trouvent à une distance dangereuse des machines.

Parmi les types de DL on trouve LSTM-NN (Long Short-Term Memory Neural Networks). Ce dernier travaille avec les données de séquences et de séries chronologiques pour les tâches de classification et de régression à l'aide de réseaux neuronaux à mémoire à court terme (LSTM). Par Exemple, en montrant comment classifier les données d'une séquence à l'aide d'un réseau neuronal LSTM [37]. Un réseau neuronal LSTM est un type de réseau neuronal récurrent ou bouclé (RNN) qui peut apprendre les dépendances à long terme entre les étapes de temps des données de séquence.


3. 3. 3 Architecture du RN-LSTM

Les composants principaux d'un réseau neuronal LSTM sont une couche d'entrée de séquence et une couche LSTM. Une couche d'entrée de séquence entre des données de séquence ou de série temporelle dans le réseau neuronal. Une couche LSTM apprend les dépendances à long terme entre les étapes temporelles des données de séquence.


Le diagramme suivant illustre l'architecture d'un réseau neuronal LSTM simple pour la classification. Le réseau neuronal commence par une couche d'entrée de séquence suivie d'une couche LSTM. Pour prédire les étiquettes de classe, le réseau neuronal se termine par une couche entièrement connectée, une couche 'softmax' et une couche de sortie de classification.



Le diagramme qui se suit illustre l'architecture d'un réseau neuronal LSTM simple pour la régression. Le réseau neural commence par une couche d'entrée de séquence suivie d'une couche LSTM. Le réseau neuronal se termine par une couche entièrement connectée et une couche de sortie de régression [37].



Le diagramme suivant illustre l'architecture d'un réseau neuronal pour la classification vidéo. Pour entrer des séquences d'images dans le réseau neuronal, utilisez une couche d'entrée de séquence. Pour utiliser des couches convolutionnelles pour extraire des fonctionnalités, c'est-à-dire appliquer les opérations convolutionnelles à chaque image des vidéos indépendamment, utilisez une couche de pliage de séquence suivie des couches convolutionnelles, puis une couche de déroulement de séquence. Pour utiliser les couches LSTM pour apprendre des séquences de vecteurs, utilisez une couche aplatie suivie des couches LSTM et de sortie [37].



3. 3. 4 Architecture de l'estimateur ANN proposée

Cette sous-section explique les étapes de conception de l'estimateur ANN perceptron non-récurrent défini par trois phases; la phase d'apprentissage, la phase de test et la phase de validation. L'architecture de notre estimateur ANN est schématisée par la **Figure. 3. 3**.

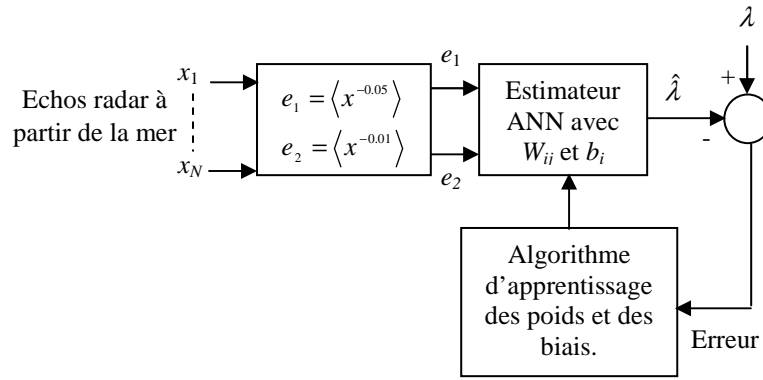


Fig. 3. 3 Architecture proposée de l'estimateur ANN des paramètres de la distribution CGIG.

(i) **Phase d'apprentissage** : Dans cette phase, nous avons considéré des données simulées CGIG distribué avec, $\mu = 1$ et un vecteur de valeurs aléatoires du paramètre de forme, λ entre 0.01 et 3.1. Le nombre d'échantillons est fixé à $N = 500$, $N = 1000$ ou $N = 10000$. Evidemment, la boucle d'apprentissage exige la connaissance des deux entrées e_1 et e_2 du ANN et qui sont données en fonction des moments empiriques d'ordres fractionnaires et négatifs. Après un certain nombre de tâtonnements, nous avons pris $r = -0.05$ et $r = -0.01$. D'où

$$\begin{cases} e_1 = \langle x^{-0.05} \rangle \\ e_2 = \langle x^{-0.01} \rangle \end{cases} \quad (3.10)$$

Rappelant que l'expression des moments théoriques d'ordre r est donnée par [4]

$$\langle z^r \rangle = \Gamma(1+r) e^{\lambda/\mu} \sqrt{\frac{\lambda}{2\pi}} \int_0^{\infty} y^{r-3/2} \exp\left(-\frac{\lambda}{2\mu^2} y - \frac{\lambda}{2y}\right) dy \quad (3.11)$$

Dans cette application et après un certain nombre de tâtonnements, nous avons choisi une couche d'entrée de deux neurones, une seule couche cachée de 34 neurones et une couche de sortie avec un seul neurone. Pour chaque valeur de λ , le réseau calcule son sortie, $\hat{\lambda}$ et l'erreur correspondante, $\lambda - \hat{\lambda}$. Selon les valeurs des erreurs obtenues, l'algorithme de la rétro-propagation de 'Marquardt-Levenberg' effectue la mise à jour des paramètres du réseau ANN appelées poids, W_{ij} et biais b_i avec un nombre égal à $3 \times 34 = 102$.

(ii) **Phase de test** : Dans cette étape, les poids et les biais optimisés sont prêts pour le calcul des estimés du paramètre de forme, λ . A cet effet, nous avons considéré des valeurs

intermédiaires de λ par rapport aux valeurs utilisées dans la phase d'apprentissage. La comparaison entre les valeurs réelles et les valeurs estimées est effectuée pour confirmer l'efficacité de l'estimateur ANN. Aussi, les calculs des moyennes des erreurs quadratiques (MSE) permettent de savoir mieux la performance de l'estimation.

(iii) **Phase de validation** : Dans cette phase, l'estimateur ANN est appliqué en utilisant des données réelles du radar enregistrées selon plusieurs conditions. La performance de ce dernier est justifiée par la bonne régression entre les CCDFs empiriques et les CCDFs théoriques.

3. 4 Comparaison des résultats d'estimation

Dans cette section, nous allons effectuer les trois étapes citées dans la section précédente.

3. 4. 1 Phase d'apprentissage

Le bloc d'entraînement du réseau ANN impose la connaissance des entrées/sortie et qui sont les vecteurs des moments d'ordres fractionnaires désigné par le vecteur X et λ désigné par lamda. L'algorithme de 'Marquardt-Levenberg' adapte le réseau après un certain temps d'itération utilisant les fonctions Matlab suivantes :

```
net = newff(X, lamda, 34);
net.trainParam.epochs = 5000;
net.trainParam.lr = 0.08;
net.trainParam.mc = 0.01;
net = train(net, X, lamda);
y = sim(net, X);
```

où $\hat{\lambda}$ est désigné par y . Pour $N = 500, 1000$ et 10000 , nous observons que les courbes réelles et prédites de λ sont presque confondues comme montré dans les **Figures. 3. 4-3. 6** respectivement. Pour lire les valeurs des poids et des biais du réseau adapté, on utilise les commandes Matlab suivantes :

```
w1 = net.IW{1}
w2 = net.LW{2}
b1 = net.b{1}
b2 = net.b{2}
```

3. 4. 2 Phase de test

Dans cette partie, nous avons considéré une courbe droite de λ qui contient des valeurs intermédiaires entre $\lambda = 0.1$ et $\lambda = 3$ avec un pas de 0.1. L'illustration des résultats d'estimation est montrée par les **Figures. 3. 7-3. 9**. On remarque que l'estimateur ANN se

converge vers les deux estimateurs existants, $\text{zlog}(z)$ et MLE avec un temps d'exécution réduit. Les Figures. 3. 10-3. 12 indique que l'estimateur ANN peut avoir des résultats des MSEs convenables pour des petites et de grandes valeurs de λ . Pour des valeurs moyennes de λ , il est montré que l'estimateur proposé offre des estimés dégradés. Dans cette étude, nous avons considéré $n = 100$ Monte-Carlo pour l'évaluation des MSEs.




Figure. 3. 4 Entrainement du réseau de neurones pour $N = 500$ et $\mu = 1$.




Figure. 3. 5 Entrainement du réseau de neurones pour $N = 1000$ et $\mu = 1$.




Figure. 3. 6 Entraînement du réseau de neurones pour $N = 10000$ et $\mu = 1$.

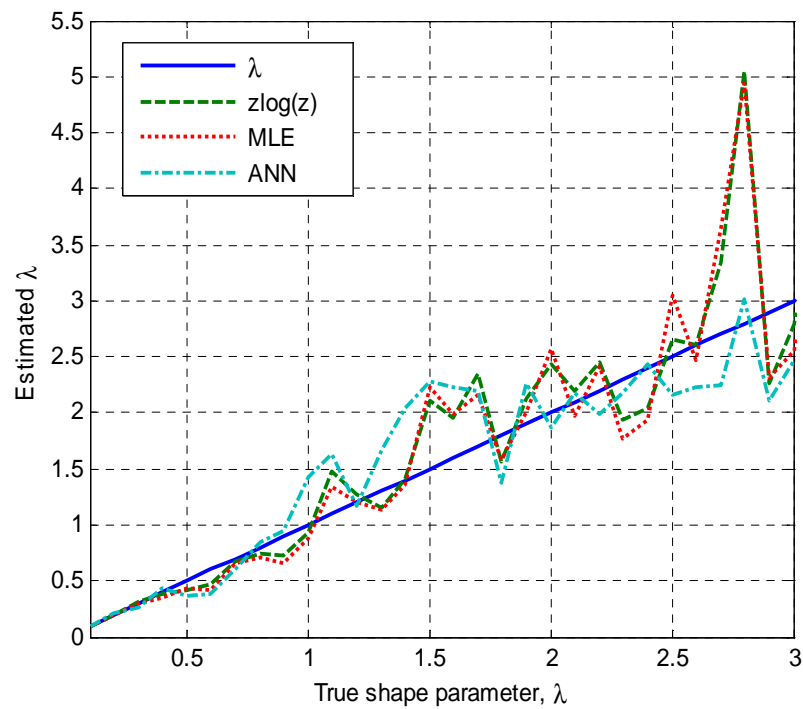


Figure. 3. 7 Phase de test du réseau de neurones pour $N = 500$ et $\mu = 1$.




Figure 3. 8 Phase de test du réseau de neurones pour $N = 1000$ et $\mu = 1$.




Figure 3. 9 Phase de test du réseau de neurones pour $N = 10000$ et $\mu = 1$.

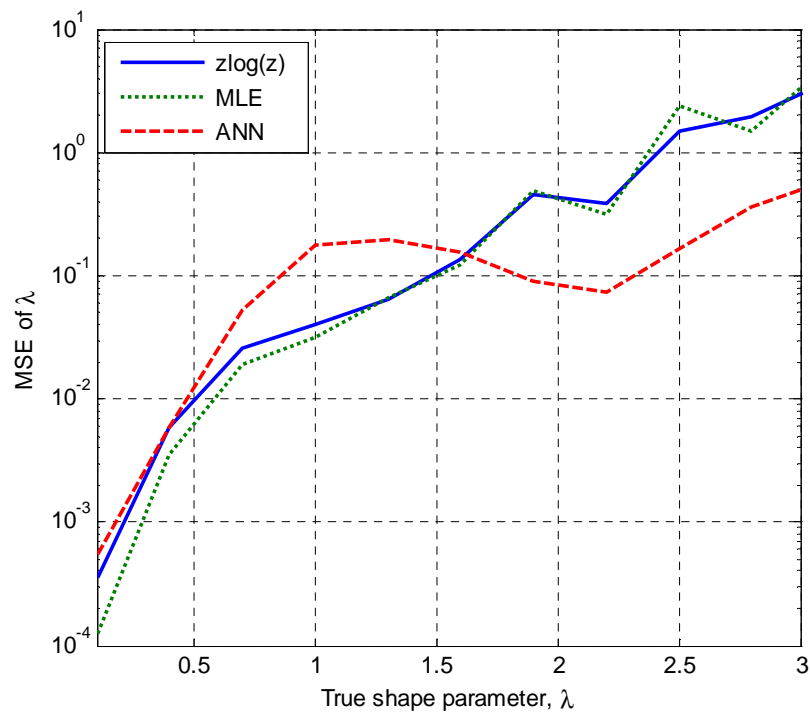


Figure. 3. 10 Comparaison des MSEs utilisant les approches d'estimation $z\log(z)$, MLE et ANN pour $n = 100$, $N = 500$ et $\mu = 1$.




Figure. 3. 11 Comparaison des MSE utilisant les approches d'estimation $z\log(z)$, MLE et ANN pour $n = 100$, $N = 1000$ et $\mu = 1$.

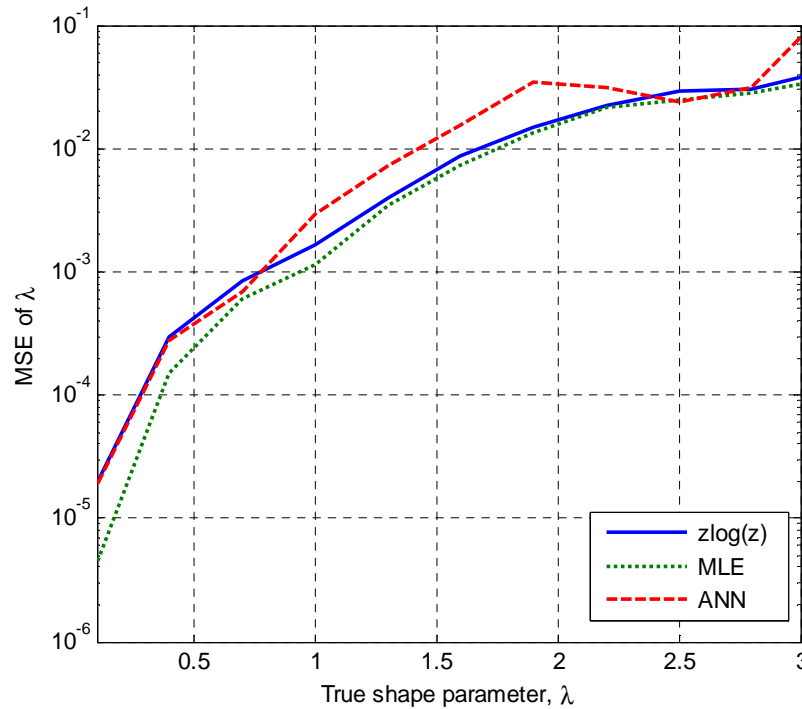


Figure. 3. 12 Comparaison des MSE utilisant les approches d'estimation $z\log(z)$, MLE et ANN pour $n = 100$, $N = 10000$ et $\mu = 1$.

3. 4. 3 Phase de validation

Après l'étude en simulation des performances de l'estimateur ANN, les données IPX sont utiles maintenant pour valider la méthode d'intelligence artificielle proposée. A cet effet, les **Figures. 3. 13-3. 18** tracent d'une manière ensemble les CCDFs théoriques et les CCDFs empiriques. Nous avons considéré plusieurs conditions de données réelles caractérisées par le changement de la résolution (3m, 15m ou 30m), le changement de la polarisation de l'antenne (HH ou VV) et le changement de la position de la cellule en portée (entre 1 et 34). Il est bien remarqué que l'estimateur ANN offre une bonne régression aux courbes réelles. Dans la majorité des cas, l'estimateur proposé présenté par la **Figure. 3. 3** donne des résultats similaires à celle de l'approche MLE appropriée au modèle CGIG. L'avantage de l'estimateur ANN réside dans le calcul direct et rapide des estimés où la recherche numérique des variables n'est prise comme le cas des estimateurs $z\log(z)$ et MLE.




Figure. 3. 13 Performances de l'estimation ANN pour une résolution 3m, 3^{ème} cellule et polarisation HH.




Figure. 3. 14 Performances de l'estimation ANN pour une résolution 15m, 14^{ème} cellule et polarisation HH.




Figure. 3. 15 Performances de l'estimation ANN pour une résolution 30m, 2^{ème} cellule et polarisation HH.




Figure. 3. 16 Performances de l'estimation ANN pour une résolution 3m, 20^{ème} cellule et polarisation VV.




Figure. 3. 17 Performances de l'estimation ANN pour une résolution 15m, 22^{ème} cellule et polarisation VV.




Figure. 3. 18 Performances de l'estimation ANN pour une résolution 30m, 15^{ème} cellule et polarisation VV.

3. 5 Conclusion

Dans ce chapitre, nous avons présenté en premier temps le mécanisme des estimateurs existants basés sur les moments d'ordres entiers, les moments d'ordre fractionnaires, les moments logarithmiques et le maximum de vraisemblance. Après, nous avons évoqué des définitions de l'approche d'intelligence artificielle inspirée de réseaux de neurones biologique. Pour ce faire, le ANN de type perceptron non-récurrent et le ANN de type LSM récurrent ont été expliqués. Comme un estimateur original du paramètre de forme du modèle CGIG, nous avons choisi l'architecture ANN non-récurrente où les trois phases de construction sont éclairées et exécutées selon des commandes Matlab. Les données synthétisées du clutter CGIG ont été prise en compte pour l'entraînement du réseau et l'étude des performances d'estimation. Il était bien montré que l'estimateur ANN se converge vers les estimateurs existants $\text{zlog}(z)$ et MLE avec un temps d'exécution minimum. Pour valider le réseau, les données réelles IPIX a été exploitée et confirment la bonne régression de l'estimateur proposé ANN dans plusieurs cas.

Conclusion Générale

Sommaire de la conclusion générale :

| | |
|------------------------------|----|
| 1. Introduction..... | 53 |
| 2. Synthèse du mémoire | 54 |
| 3. Travaux futurs | 55 |

1. Introduction

Ce mémoire a traité le problème de modélisation du clutter marin à haute résolution et le problème d'estimation des paramètres du modèle statistique CGIG, appliquées à la détection des cibles radar qui se déplacent au-dessus de la mer. A cet effet, on a considéré premièrement des données réelles IPIX pour l'analyse de la modélisation du clutter IPIX par les lois CGIG et mixture CGIG. La technique d'intelligence artificielle (ANN) a été considérée ensuite pour l'estimation du paramètre de forme du clutter CGIG distribué. Grâce aux progrès réalisés dans le traitement numérique du signal, les applications de l'intelligence artificielle opérationnelles actuelles sont devenues possibles. Aujourd'hui, c'est sur la technologie des processeurs que se porte l'effort, et de grands espoirs se fondent sur l'entraînement des ANNs avec un volume de données énorme (big data).

2. Synthèse du mémoire

Dans ce mémoire, nous avons effectué les tâches de recherche suivantes :

Dans le **Chapitre 1**, nous avons présenté en premier temps l'historique et les applications modernes de l'équipement radar. Après, nous avons expliqué brièvement le principe de fonctionnement de radar à impulsions ainsi que les différents types de ce système à savoir les radars primaires et les radars secondaires. Puisque les cibles représentent des sources de signaux réfléchis aléatoires, les quatre modèles de Swerling ont été donnés représentant les fluctuations des surfaces équivalentes des avions, des navires, des missiles, etc. Enfin, nous avons évoqué les statistiques des échos indésirables (clutter) par des distributions gaussiennes et non-gaussiennes.

Dans le **Chapitre 2**, la modélisation du clutter marin basée sur l'utilisation de la base de données IPIX a été étudiée et analysée. Pour ce faire, des modèles non-gaussiens ont été considérés tels que Weibull, log-normal, K , Pareto type II, CGIG et mixture CGIG. Les estimateurs MLE et LSA ont été appliqués pour obtenir les paramètres des modèles en question à partir des échantillons de la surface de la mer. Plusieurs scènes de données réelles IPIX enregistrées en fonction des paramètres radar comme la polarisation de l'antenne HH, VV, VH ou HV, résolution de cellules 3m, 15m ou 30m et différentes cellules de portée ont été prises en compte pour évaluer les performances de modélisation des distributions ci-dessus. Il était bien conclu que les modèles CGIG et mixture CGIG sont les plus adaptés pour la plus part des cas.

Dans le **Chapitre 3**, nous avons présenté en premier temps le mécanisme des estimateurs existants basés sur les moments d'ordres entiers, les moments d'ordre fractionnaires, les moments logarithmiques et le maximum de vraisemblance. Après, nous avons évoqué des définitions de l'approche d'intelligence artificielle inspirée de réseaux de neurones biologique. Pour ce faire, le ANN de type perceptron non-récurrent et le ANN de type LSM récurrent ont été expliqués. Comme un estimateur original du paramètre de forme du modèle CGIG, nous avons choisi l'architecture ANN non-récurrente où les trois phases de construction sont éclairées et exécutées selon des commandes Matlab. Les données synthétisées du clutter CGIG ont été prise en compte pour l'entraînement du réseau et l'étude des performances d'estimation. Il était bien montré que l'estimateur ANN se converge vers les estimateurs existants $\log(z)$ et MLE avec un temps d'exécution minimum. Pour valider le réseau, les données réelles IPIX a été exploitée et confirment la bonne régression de l'estimateur proposé ANN dans plusieurs cas.

3. Travaux futurs

Comme suggestions pour des travaux futurs, on peut envisager les problèmes de recherche suivants :

- A cause des complexités mathématiques, la détection non-cohérente CFAR dans un clutter CGIG n'est pas encore développée. Il est très important d'appliquer l'ANN-LSTM (Deep-Learning) pour résoudre ce problème de détection.
- La modélisation du clutter IPIX peut améliorer par l'utilisation de la distribution CGIG trimodal (une mixture de 3 distributions CGIG).

Références

- [1] Radar overview:
<https://en.wikipedia.org/wiki/Radar>
- [2] V. G. Anastassopoulos, A. Lampropoulos, A. Drosopoulos and M. Rey, "High resolution radar clutter statistics", *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 35, no. 1, pp. 43-60, 1999.
- [3] S. Watts and L. Rosenberg, "Challenges in radar sea clutter modeling", *IET Radar Sonar & Navigation, Special Issue*, 2022.
- [4] A. Mezache, A. Bentoumi and M. Sahed, "Parameter estimation for compound-Gaussian clutter with inverse-Gaussian texture", *IET Radar Sonar & Navigation*, Vol. 11, no. 4, pp. 586-596, 2017.
- [5] H. M. Finn and R. S. Johnson, "Adaptive detection model with threshold control as a function of spatially sampled clutter-level estimates", *RCA Review*, Vol. 29, pp. 414-464, 1968.
- [6] V. G Hansen and J. H. Sawyers, "Detectability loss due to greatest-of selection in a cell averaging CFAR", *IEEE Transactions on Aerospace and Electronic Systems*, Vol. AES-16, pp. 115-118, 1980.
- [7] G. V. Trunk, "Range resolution of targets using automatic detectors", *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 14, no. 5, pp. 750-755, 1978.
- [8] H. Rohling, "Radar CFAR thresholding in clutter and multiple target situations", *IEEE Transactions on Aerospace and Electronic Systems*, Vol. AES-19, pp. 608-621, 1983.
- [9] R. Ravid and N. Levanon, "Maximum-likelihood CFAR for Weibull background", *IEE Proceedings-F*, Vol. 13, no. 3, pp. 256-264, 1992.
- [10] K. Cheikh and S. Faozi, "Application of neural networks to radar signal detection in K-distributed clutter", *First International Symposium on Control, Communications and Signal Processing*, 21-24 March 2004, Hammamet, Tunisia.
- [11] Radar systems:
<https://www.waves.utoronto.ca/prof/svhum/ece422/notes/24-radar.pdf>].
- [12] Radar applications:
<https://ftp.idu.ac.id/wpcontent/uploads/ebook/>

- [13] H. Halitim et Z. Ouled Mahddine, "Modélisation et détection CFAR dans un clutter de la mer de distribution Weibull Mélangée", Mémoire de Master, Université de msila, 2022.
- [14] F. Belamri et B. Saoudi, "Analyse de performance du détecteur TGM-CFAR dans un clutter non-homogene de destribtion pareto", Memoire de Master, Université de msila, 2021.
- [15] B. R. Mahafza, "Radar systems analysis and design using Matlab", Chapman & /CRC, USA, 2000.
- [16] Y. Blanchard, "Le radar, 1904-2004 : Histoire d'un siècle d'innovations techniques et opérationnelles", Éditions Ellipses, 2004.
- [17] M. Barkat, "*Signal detection and estimation*", 2nd edition, Artech House, Boston, USA, 2005.
- [18] A. Gouri, "*Modeling, Estimation and CFAR Detection in non-Gaussian Clutter*", Doctorate thesis, Department of Electronics, Msila University, Algeria, 2020.
- [19] A. Bentoumi, "*Contribution à l'estimation et la détection CFAR de cibles noyées en milieux de clutter de mer non-Gaussien homogène et hétérogène*", Doctorate thesis, Department of Electronics, Msila University, Algeria, 2020.
- [20] J. Ai *et al*, "A new two parameter CFAR ship detector in log-normal clutter", *IEEE Radar Conference*, 08-12 May 2017, Seattle, WA, USA.
- [21] B. Zhang, J. Zhou, J. Xie and W. Zhou, "Weighted likelihood CFAR detection for Weibull background", *Digital Signal Processing*, Vol. 115, 2021.
- [22] J. R. Nicholas, "Estimating the parameters of the K -distribution in the intensity domain", *DSTO-TR-0839, Electronics and Surveillance Research Laboratory*, pp. 1-76, 1999.
- [23] S. Bocquet, "Simulation of Correlated Pareto distributed sea clutter", *International Conference on Radar*, 09-12 September 2013, Adelaide, SA, Australia.
- [24] X. Zhou, R. Peng, C. Wang, "A two-component K -lognormal mixture model and its parameter estimation method", *IEEE Transaction on Geosciences and Remote Sensing*, Vol. 53, no. 5, pp. 2640-2651, 2015.
- [25] Z. Terki, A. Mezache and F. Chebbara, "Modeling and parameter estimation of radar sea-clutter with trimodal gamma population", *Journal of Telecommunications and Information Technology*, Vol. 2, pp. 82-90, 2022.
- [26] M. S. Aminbzadeh and M. Deng, "Bayesian predictive modeling for inverse Gamma-Pareto composite distribution", *Communications in Statistics, Theory and Methods*, Vol. 48, no. 8, pp. 1938-1954, 2019.
- [27] G. B. Goldstein, "False-alarm regulation in log-normal and Weibull clutter", *IEEE Transactions on Aerospace and Electronic Systems, AES-9*. Vol. 1, pp. 84-92, 1973.

- [28] S. Bocquet, "Parameter estimation for Pareto and K -distributed clutter with noise", *IET Radar, Sonar & Navigation*, Vol. 9, no. 1, pp. 104-113, 2015.
- [29] K. Ward, R. J. A. Tough and S. Watts, "*Sea Clutter: Scattering, the K -distribution and radar performance*", IET Radar, Sonar & Navigation, Series 20, 2006, London, UK.
- [30] A. Mezache, F. Soltani, M. Sahed and I. Chalabi, "Model for non-Rayleigh clutter amplitudes using compound inverse Gaussian distribution: An experimental analysis", *IEEE Transactions on Aerospace and Electronic Systems*, Vol. 51, no. 1, pp. 142-153, 2015.
- [31] R. B. Bakker and B. Currie, B. "The McMaster IPIX Radar Sea Clutter Database", Online available: <http://soma.crl.mcmaster.ca/ipix/>
- [32] Y. C. Gao, G. S. Liao and S. Q. Zhu, "Adaptive signal detection in compound-Gaussian clutter with inverse Gaussian texture", *IEEE 14th International Radar Symposium (IRS)*, 19-21 June 2013, Dresden, Germany.
- [33] Neural networks:
https://fr.wikipedia.org/wiki/R%C3%A9seau_de_neurones_artificiels
- [34] F. Rosenblatt, "*Principles of Neurodynamics*", Washington D.C., Spartan Press, 1961
- [35] Deep-Learning:
<https://www.mathworks.com/help/deeplearning/ug/deep-learning-in-matlab.html>
- [36] M. Amitha, P. Amudha and S. Sivakumari, "*Deep Learning Techniques: An Overview*", Part of the Advances in Intelligent Systems and Computing, book series (AISC, volume 1141)
- [37] LSTM neural Networks:
<https://www.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>.