

République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieure et de la Recherche
Scientifique



Université Abderrahmane Mira

Faculté de la Technologie



Département d'Automatique, Télécommunication et d'Electronique

Projet de Fin d'Etudes

Pour l'obtention du diplôme de Master

Filière : **Télécommunication.**

Spécialité : **Réseaux et Télécommunications.**

Thème

**Classification Automatique de Modulation à base
du Deep Learning**

Préparé par :

M^{lle} Ait CHADI Lydia

M^{lle} AINENNAS Silia

Dirigé par :

M M.TOUNSI

M D.BEKNADJ

Examiné par :

M. S.HADJI

M. M.AZNI.

Année universitaire : 2021/2022

Remerciements

Il est venu le temps de mettre un point final à ce travail et à toutes ces années effectuées au sein de l'université d'Abderrahmane Mira de Bejaia.

Nous remercions avant tout, ALLAH le tout puissant, de nous avoir donné la force et la volonté de réaliser et de terminer ce projet de fin d'études.

C'est avec un grand plaisir que nous adressons nos sincères remerciements à nos encadrants : Mr TOUNSI et Mr BEKNADJ Dalil pour la confiance dont ils ont toujours fait preuve à notre égard et leurs perpétuels encouragements.

Nos sincères remerciements vont aux honorables membres du jury pour l'intérêt porté à notre travail en acceptant son évaluation.

Enfin dans les dernières lignes nous tenons à remercier les personnes qui ont contribué à la réussite de ce projet de loin ou de près.

Dédicaces

Je dédie ce modeste travail à :

Ma chère mère qui m'a dotée d'une éducation digne et m'a soutenue durant toutes mes études, elle a fait de moi ce que je suis aujourd'hui je lui serai éternellement reconnaissante, que dieu la garde en bonne santé.

À la mémoire de mon père décédé trop tôt, j'espère qu'il apprécie cet humble geste comme preuve de reconnaissance de la part de sa fille qui a toujours prié que Dieu le tout puissant l'accueille dans son vaste paradis.

À mon frère, qui m'a soutenue et qui a été présent à mes cotées, tu as su m'accompagner durant cette épreuve, comme tu l'as fait à chaque étape de ma vie, tu n'es pas juste un frère mais tu as pu combler l'absence de mon père. Que ce travail soit l'exaucement de tes vœux tant formulés et tes prières quotidiennes

À ma sœur et mon frère : Yasmina, Samir.

À mes neveux : Lília, Salah.

À mes chers grands parents à qui je leur souhaite une longue vie.

À mes cousins et cousines : Ines, Hamid.

À ma binôme Sílía et toute sa famille.

À toutes mes ami(e)s : Lynda, Yasmina, Sonia, Kenza, Hannane et celles de la promotion de Télécommunication.

À tous les membres de ma famille et toutes les personnes qui m'aiment.

« Lydia »

Dédicaces

Je dédie ce modeste travail à :

À la mémoire de ma grand-mère « Yemma » et mon unique oncle maternel « Dadda », pour l'amour dont vous m'avez entourée, pour tout ce que vous avez fait pour moi, pour vous qui ont fait en moi une femme indépendante, vous m'avez appris à être forte, responsable et à surmonter tous les grands défis, vous avez fait en moi ce que je suis aujourd'hui. Chaque souvenir de vous restera à jamais dans mon âme et tant que mon cœur battra, vous serez présents en moi et avec moi. Je ferai de mon mieux pour rester un sujet de fierté à vos yeux. Que ce modeste travail soit le fruit de tous les sacrifices que vous avez déployés pour mon éducation et ma formation. Que dieu le tout puissant vous accorde son vaste paradis.

À mes parents, pour leurs amours, affections, leurs encouragements et sacrifices et la confiance qu'ils m'ont accordée. Que dieu les garde en bonne santé.

À mon unique sœur : Lydia.

À mes tantes : Nacira, Mina, Sabiha, Assia, Karima, Linda, Faïka.

À mes cousins et cousines : Rayane, Lyticia, Aïcha, Sissa, Yasmine, Fatima, Warda, Meriem, Midou, Imane, Ikram, Fares, Alicia.

À ma binôme Lydia et toute sa famille.

À tous mes ami(e)s : Souhila, Sonia, Yasmina, Hannane, célia, Ghania et ceux de la promotion de Télécommunication.

À tous les membres de ma famille et toutes les personnes qui m'aiment.

« Sília »

Table des matières

Introduction générale	1
------------------------------------	----------

Chapitre I : Introduction à la Radio Cognitive

I.1	Introduction	3
I.2	Radio logicielle (software radio)	3
I.3	Radio logicielle restreinte (SDR)	3
I.4	Radio cognitive (RC)	4
I.4.1	Définition	4
I.4.2	Principe	5
I.4.3	Relation entre RC et SDR	5
I.5	Les fonctions de la RC	6
I.5.1	Détection du spectre (spectrum sensing)	6
I.5.2	Gestion du spectre (Spectrum management)	6
I.5.3	Mobilité du spectre (Spectrum mobility)	6
I.5.4	Décision sur le spectre (Spectrum decision)	6
I.5.5	Partage du spectre (Spectrum sharing)	6
I.6	Type de détection de spectre	7
I.6.1	Détection dans un système non coopératif	8
I.6.2	Détection d'énergie	8
I.6.3	Détection par filtre adapté	8
I.6.4	Détection des caractéristiques cyclo stationnaires	8
I.6.5	Détection dans un système coopératif	8
I.6.6	La technique distribuée	9
I.6.7	La technique centralisée	9
I.6.8	Détection basée sur les interférences	9
I.7	Architecture de la RC	9
I.8	Cycle de cognition	10

I.9	Applications de la Radio cognitive	11
I.10	Conclusion.....	11

Chapitre II : L'AMR dans les systèmes de communications numériques

II.1	Introduction	12
II.2	La reconnaissance automatique de la modulation (AMR).....	12
II.2.1	Domaine d'application de l'AMR	12
	• Applications dans le domaine militaire	12
	• Applications civiles	13
II.2.2	Méthodologie de classification AMR	14
II.2.3	SVM (Support Vector Machine).....	14
II.2.4	ANN (Artificiel Neural Network).....	16
II.2.5	KNN (k-Nearest Neighbors)	17
II.4.	Rappels de Notions de communications numériques	18
II.2.6	Modulation numérique.....	18
II.2.7	Types de modulations numériques.....	18
	• QAM (Quadrature Amplitude Modulation)	18
	• PSK (Pulse Shift Keying).....	19
II.2.8	Critères de choix d'une modulation numérique.....	20
	• BER (Bit Error Rate).....	20
	• SNR (Signal to noise ratio)	21
	• Efficacité spectrale	21
II.2.9	Canaux de propagation	21
II.2.10	Les modèles de canaux de propagations	22
	• Modèle déterministe	22
	• Modèle statistique (stochastique)	22
II.2.11	Caractéristique du canal de propagation	22
	• Effet Doppler	22
	• Temps de cohérence (cohérence time)	23

• Bande de cohérence (cohérence bandwidth)	23
II.2.12 L'évanouissement	23
• Évanouissements dû à la dispersion temporelle	23
• Évanouissement dû au décalage doppler.....	24
II.2.13 Modèles de canaux de transmission.....	24
• Canal Bruit Blanc Gaussien Additif (AWGN).....	25
• Canal de Rice	26
• Canal de Rayleigh	27
II.3 Conclusion	28

Chapitre III : Notions de Deep Learning

III.1 Introduction	30
III.2. Rappels et Terminologie.....	30
III.2.1. Historique	30
III.2.2. Intelligence artificielle	31
III.2.3. Machine Learning	32
III.2.4. Deep Learning	32
III.3. Bases des réseaux de neurones	33
III.3.1. Neurone biologique	33
III.3.2. Perceptron	34
III.3.3. Réseaux ANN (Artificiel neural network).....	35
III.3.3.1. Propriétés des ANN	35
III.3.3.2. La fonction d'activation	36
III.3.3.3. Fonction cout (Cost function).....	37
III.3.3.4. Retro-propagation	37
III.3.3.5. Architecture d'un réseau ANN.....	38
III.3.3.5.1. Réseau à couches	39
III.3.3.5.2. Réseaux récurrents.....	40
III.3.3.6. Types d'apprentissages des réseaux de neurones	41

III.4. Réseau de neurones convolutif	42
III.4.1. Architecture des réseaux convolutifs	42
III.4.1.1. Partie convolutive	43
III.4.1.2. Partie classification	46
III.4.2. Types d'architectures CNN	48
III.4.3. Paramètres convolutifs	48
III.4.4. Avantages de CNN	49
III.4.5. Applications des CNN	49
III.5. Conclusion	49

Chapitre IV : Simulations AMC à base d'un réseau CNN

IV.1 Introduction	50
IV.2 Classification de types de modulations à base des réseaux de neurones convolutifs ..	50
IV.3 Environnement de travail	50
IV.4 Évaluation des performances de classifieur	50
IV.4.1 La matrice de confusion	51
IV.4.2 La courbe ROC (Receiver Operating Characteristic)	52
IV.5 Méthodologie de simulation	52
IV.5.1 Réseau de neurone utilisé	56
IV.5.2 Simulations	57
• Évaluation du taux de classification correcte	57
• Évaluation des matrices de confusion	62
• Évaluation de la courbe ROC	64
IV.6 Conclusion	66
Conclusion générale	67

Liste des figures

Figure I.1 : Un récepteur radio basé sur SDR.....	4
Figure I.2 : Relation entre les radios RC et SDR.....	5
Figure I.3 : Les fonctions de la RC.....	7
Figure I.4 : Types de détection du spectre.....	8
Figure I.5 : Architecture de la radio cognitive.....	9
Figure II.1 : Principe de reconnaissance automatique de type de modulation.	12
Figure II.2 : schéma d'une communication numérique dans le domaine militaire.	13
Figure II.3 : Schéma d'une communication numérique dans le domaine civile.	14
Figure II.4 : Cas linéaire de la technique SVM.	15
Figure II.5 : Cas non-linéaire de la technique SVM.....	15
Figure II.6 : Architecture d'un réseau de neurones multicouches.....	16
Figure II.7 : Exemple d'un classifieur KNN avec K=3 et 7.	17
Figure II.8 : Constellation M-QAM	19
Figure II.9 : Constellations 4-QAM.	19
Figure II.10 : Constellations M-PSK.....	20
Figure II.11 : Constellations 8PSK.....	20
Figure II.12 : Canal de propagation.....	21
Figure II.13 : Types de modèles des canaux de propagation.....	22
Figure II.14 : Types des évanouissements.....	24
Figure II.15 : Canal AWGN.	26
Figure II.16 : Distribution d'un canal AWGN.	26
Figure II.17 : Propagation multi-trajets LOS.....	27
Figure II.18 : Distribution de Rice.....	27
Figure II.19 : Propagation multi-trajets NLOS.....	28
Figure II.20 : Distribution de Rayleigh.....	28
Figure III.1 : Relation Deep Learning/Machine/Learning / IA.	31
Figure III.2 : Neurone biologique.....	33
Figure III.3 : Perceptron monocouche.....	34
Figure III.4 : Réseau de neurones artificiels avec une seule couche cachée.	35
Figure III.5 : La fonction convexe.....	37
Figure III.6 : Architecture d'un réseau de neurones artificiels.	39
Figure III.7 : Réseau sans couche cachée.	40
Figure III.8 : Réseau à une couche cachée.	40

Figure III.9 : Réseau de neurones récurrent.....	41
Figure III.10 : Architecture d'un réseau de neurones convolutif.	43
Figure III.11 : Le principe de la marge à zéro.	44
Figure III.12 : Technique de balayage d'image avec filtre convolutif.....	45
Figure III.13 : La fonction d'activation ReLU.....	45
Figure III.14 : Technique de pooling.....	46
Figure III.15 : La fonction d'activation Softmax.	47
Figure III.16: : Partie classification d'un CNN.....	48
Figure IV.1 : Matrice de confusion.....	51
Figure IV.2 : Interprétation de la courbe ROC.....	52
Figure IV.3 : Méthodologie de simulation.	53
Figure IV.4 : Déclaration des modulations.....	53
Figure IV.5 : Répartition des pourcentages.	54
Figure IV.6 : Génération des données.	54
Figure IV.7 : Sauvegarde des données.	54
Figure IV.8 : Les trames générées.	55
Figure IV.9 : Appel du modèle.....	55
Figure IV.10 : Entraînement CNN.....	55
Figure IV.11 : Classification des modulations.	56
Figure IV.12 : Architecture du modèle CNN utilisé.....	56
Figure IV.13 : Paramètres d'évaluation.....	57
Figure IV.14 : Taux de classification pour SNR=-15 dB.....	58
Figure IV.15 : Taux de classification avec SNR=0 dB	59
Figure IV.16 : Taux de classification pour SNR=15 dB.	60
Figure IV.17 : Taux de classification pour SNR=30 dB.	61
Figure IV.18 : La courbe ROC pour SNR=-15dB.....	64
Figure IV.19 : La courbe ROC pour SNR=0dB.	65
Figure IV.20 : La courbe ROC pour SNR=30dB.	65
Figure IV.21 : La courbe ROC pour SNR=30dB.....	66

Liste des tableaux

Tableau III.1 : Comparaison entre le neurone biologique et le neurone artificiel.....	34
Tableau III.2 : Les fonctions d'activations.....	36
Tableau IV.1 : Métriques de performance d'un classifieur.....	51
Tableau IV.2 : Récapitulatif des différentes simulations.....	62
Tableau IV.3 : Matrice de confusion pour SNR=-15 dB.....	62
Tableau IV.4 : Matrice de confusion pour SNR=0 dB.....	63
Tableau IV.5 : Matrice de confusion pour SNR=15 dB.....	63
Tableau IV.6 : Matrice de confusion pour SNR=30 dB.....	63

Liste des acronymes

AMR	Automatic Modulation Recognition
AMC	Automatic Modulation Classification
ANN	Artificial Neural Network
ADC	Analog to Digital Converter
AWGN	Additive White Gaussian Noise
AUC	Area Under the Curve
BPTT	Back Propagation Through Time
BER	Bit Error Rate
BPSK	Binary Phase-Shift Keying
CNN	Convolutional Neural Network
CPU	Central Processing Unit
DL	Deep Learning
DNN	Deep Neural Network
FC	Fully Connected
GPU	Graphic Processing Unit
IA	Artificial Intelligence
KNN	K-Nearest Neighbours
LSTM	Long Short Term Memory
LOS	Line Of Sight
ML	Machine Learning
MLP	Multi-Layer Perceptron
MNIST	Mixed National Institute of Standards and Technology
NLOS	None Line Of Sight
PSK	Phase-Shift Keying

QAM	Quadrature Amplitude Modulation
QPSK	Quadrature Phase-Shift Keying
QoS	Quality of service
RC	Radio Cognitive
RF	Radio Fréquence
RNA	Réseaux de neurones artificiels
ReLU	Rectified Linear Unit
RNN	Recurent Neural Network
ROC	Receiver Operating Characteristic
SR	Software Radio
SDR	Software-Defined Radio
SVM	Support Vector Machines (Séparateurs à vaste marge)
SNR	Signal to Noise Ratio

Introduction générale

Différentes innovations technologiques ont vu le jour dans les systèmes de communication sans fil depuis les années 1990. Cela a permis une formidable expansion des services avec des performances de plus en plus améliorées au point que de nos jours, l'on a commencé à intégrer des fonctions d'intelligence artificielles dans les émetteurs/récepteurs. C'est ainsi que le concept de radio cognitive est apparu, avec pour objectif de doter des équipements radio de capacités cognitives pour apprendre et s'adapter en fonction de leur environnement.

C'est dans ce contexte que s'inscrit notre présent travail de fin d'études de Master en télécommunications. Nous explorons l'une des fonctions phares de la radio cognitive à savoir la reconnaissance automatique de modulation dans les réseaux sans fil

La reconnaissance ou la classification automatique de modulation (AMRC) trouve son intérêt dans des applications militaires comme la surveillance et l'analyse des menaces nécessitant la connaissance de types de modulations utilisées afin de récupérer les signaux interceptés et d'analyser les transmissions adverses. Dans les applications civiles, une telle fonctionnalité est très utile dans les systèmes de communications à schéma de codage et de modulation dynamiques. La démodulation des signaux deviendrait beaucoup plus aisée.

Notre travail consiste à élaborer un classifieur automatique du type de modulations de communications numériques à trajets multiples sur la base d'un apprentissage automatique profond. Il s'agit de proposer ainsi un réseau de neurones convolutif performant qui permettra de prédire le type de modulations des signaux traités.

Nous avons synthétisé notre travail dans ce mémoire organisé en quatre chapitres :

- Dans le premier chapitre, nous présentons les principes fondamentaux de la radio cognitive ainsi que son intérêt ;
- Le second chapitre est réservé à la tâche de classification automatique de modulations dans des systèmes de communications numériques avec un rappel sur les modèles de canaux de transmission à trajets multiples ;
- Le troisième chapitre traite de notions d'apprentissage profond (Deep Learning) pour introduire l'architecture et expliciter l'avènement et le fonctionnement des réseaux de neurones convolutifs ;

- Le dernier chapitre est consacré à des simulations sous Matlab sur une classification automatique de modulations avec un modèle de réseau de neurones convolutif et à l'évaluation de ses performances selon diverses métriques ;
- Enfin, une conclusion générale dresse un bilan de ce travail, suivie des références bibliographiques utilisées.

Chapitre I

Introduction à la Radio Cognitive

I.1 Introduction

Le développement de la Radio Cognitive (RC) est venu en réponse à l'émergence et au développement d'une multitude de standards de communications exploitant la bande des radio fréquences. L'élargissement de l'éventail des offres et des services pour les utilisateurs avec des exigences de qualité de service de plus en plus accrues, a compliqué le problème de rareté du spectre RF. L'idée fondamentale de la RC est d'exploiter au mieux les bandes de fréquences déjà allouées, souvent de façon non optimisée [1] en dotant les terminaux de nouvelles fonctions leur permettant d'interagir avec leur environnement. Un terminal pourra donc détecter les fréquences libres et les utiliser de manière dynamique, contribuant ainsi à une meilleure efficacité spectrale et une meilleure qualité de service avec des débits plus importants.

Au cours de ce chapitre, nous allons présenter la radio cognitive sous ses différents aspects, à savoir son fonctionnement, son architecture et ses enjeux.

I.2 Radio logicielle (software radio)

La radio logicielle définit une classe de radio reprogrammable et reconfigurable, apparue dans les années 90, réalisée principalement par logiciel et dans une moindre mesure par matériel et inspirée de la radio logicielle idéale dans le but est de dématérialiser l'interface radio. Celle-ci est composée d'une antenne et d'un convertisseur analogique-numérique ADC, dans laquelle les fonctions d'interfaçage radio, telles que les caractéristiques (la fréquence porteuse, la largeur de bande du signal, la modulation) sont passées du matériel au logiciel. La radio logicielle s'est développée et permet de nos jours, l'implantation logicielle de procédés de cryptographie, de codage correcteur d'erreur, de codage source de la voix, de la vidéo ou des données dans les réseaux de communication.

I.3 Radio logicielle restreinte (SDR)

La radio logicielle qui a pour but d'intégrer diverses fonctionnalités en logiciel, impose la combinaison entre anciennes et nouvelles techniques à travers des phases intermédiaires qui résolvent les contraintes de puissance de calcul, de consommation électrique, de coûts, ...etc. On parle alors de radio logicielle restreinte (SDR : Software Defined Radio) considérée comme étant le plus haut niveau d'avancement de la radio logicielle. Les équipements SDR peuvent fonctionner dans des réseaux sans fil hétérogènes de façon à se conformer automatiquement aux nouvelles fréquences et aux nouvelles modulations. La flexibilité de la SDR permet une adaptation à différents protocoles de radiocommunication et de répondre au besoin croissant de performance et d'interopérabilité entre systèmes [2].

Les SDR se divisent en une partie analogique et une partie numérique tel que représentée sur la figure ci-dessous. La partie analogique, composée de l'antenne et du modulateur RF à l'entrée du système, permet de capter l'onde radio puis de la transformer en un signal de fréquence intermédiaire. L'autre partie commence par une conversion analogique/numérique (ADC) qui permet d'obtenir un signal numérique en sortie prêt à subir différents traitements numériques, ce principe est illustré par la figure ci-dessous :

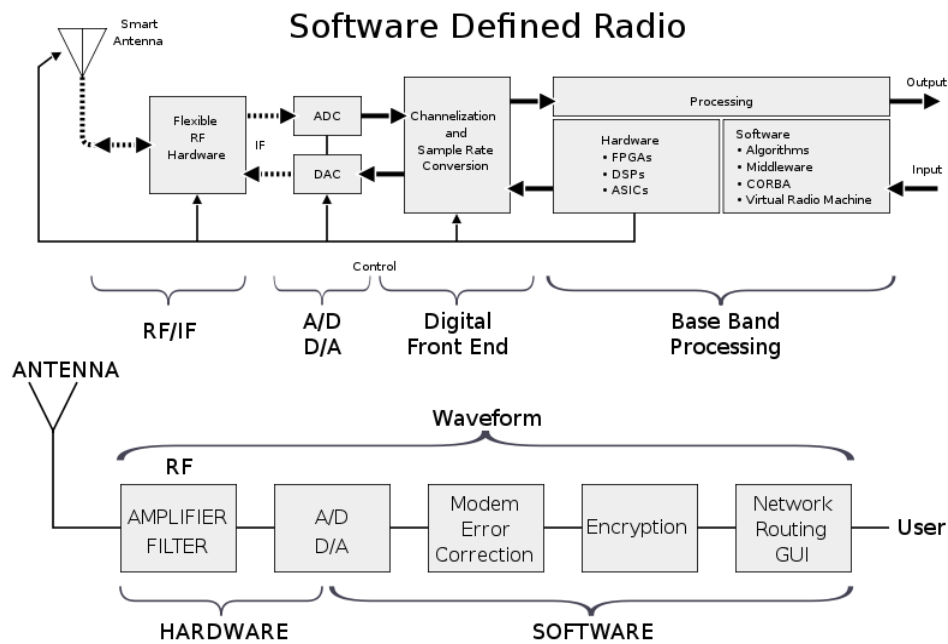


Figure I.1 : Un récepteur radio basé sur SDR.

I.4 Radio cognitive (RC)

I.4.1 Définition

La radio cognitive est une technologie reprise dans la norme IEEE 802.22 et qui fait appel à l'intelligence des réseaux et des terminaux pour détecter les besoins de communications des abonnés en fonction de l'utilisation, offrant ainsi des ressources radio et des services sans fil les plus appropriés à ces besoins.

L'idée de la radio cognitive a été présentée officiellement par Joseph Mitola en 1999 et se résume ainsi : « Une radio cognitive peut connaître, percevoir et apprendre de son environnement puis agir pour simplifier la vie de l'utilisateur » [3].

La RC est une forme de communication sans fil programmée et configurée dynamiquement dans laquelle les utilisateurs peuvent détecter intelligemment les canaux de communication utilisés et ceux qui ne le sont pas pour pouvoir les occuper. Ceci permet d'optimiser les fréquences spectrales disponibles et offre donc aux utilisateurs un accès plus souple et efficace.

I.4.2 Principe

Le défi le plus important lors de l'émergence de la radio cognitive est de partager le spectre autorisé de façon à répondre aux besoins d'un maximum d'abonnés alors que la majeure partie du spectre est déjà assignée. Cette technique permet l'utilisation de spectre temporellement inutilisé, qui est mentionné comme trou de spectre. Si cette bande est encore utilisée par un utilisateur autorisé PU (*Primary User*), la RC offre des mouvements à un autre espace, en changeant ces paramètres pour éviter toute interférence qui peut dégrader la communication.

Dans une communication radio cognitive, deux protagonistes se présentent :

- Utilisateurs primaires PU (*Primary Users*) : ce sont les utilisateurs ayant une licence qui leur attribue des portions du spectre, en communiquant en toute liberté à tout instant sur leurs bandes autorisées.
- Utilisateurs secondaires SU (*Secondary Users*) : ce sont des utilisateurs sans licence qui interviennent dans le spectre de façon opportuniste, sans causer d'interférences avec les utilisateurs PU. Néanmoins, les systèmes sans fil existants ont été conçus pour fonctionner sur des fréquences dédiées. Les utilisateurs SU n'exploitent donc les trous de fréquences que lorsque les utilisateurs PU sont inactifs, donc qui libèrent la ressource à un temps donné et à un emplacement géographique spécifique.

I.4.3 Relation entre RC et SDR

La RC repose sur la capacité d'adaptation même avec la présence de plusieurs facteurs qui peuvent modifier les paramètres radio (fréquence porteuse, puissance, modulation, bande passante) et cela en se basant sur le principe de la SDR qui offre à son tour des fonctionnalités de flexibilité et de reconfigurabilité [4]. Par conséquent, la mise en œuvre d'une RC repose sur un noyau SDR, voir la figure :

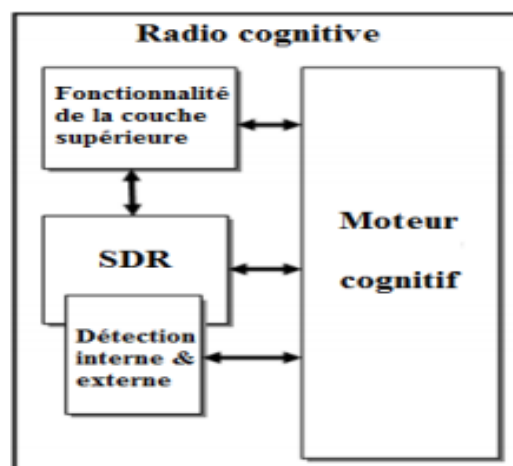


Figure I.2 : Relation entre les radios RC et SDR.

I.5 Les fonctions de la RC

La radio cognitive présente un ensemble de fonctions qui sont les suivantes [5]:

I.5.1 Détection du spectre (spectrum sensing)

Détection des portions du spectre vides par détection de signaux d'utilisateurs PU afin de les partager sans interférence avec d'autres usagers. Elle représente la façon selon laquelle les espaces non utilisés sont capturés pour obtenir le statut de spectre libre et/ou occupé, de sorte qu'un utilisateur SU peut consulter cette bande temporellement.

I.5.2 Gestion du spectre (Spectrum management)

Dans le but de répondre aux besoins de communication des utilisateurs SU, le système RC capte la meilleure bande de spectre disponible pour satisfaire les exigences de qualité de service.

I.5.3 Mobilité du spectre (Spectrum mobility)

Lorsqu'un utilisateur PU accède à nouveau à son canal, un processus permet à l'utilisateur SU de changer sa fréquence de manière dynamique en permettant de maintenir les exigences au cours de la transition à d'autres bandes de fréquences.

I.5.4 Décision sur le spectre (Spectrum decision)

L'utilisateur SU se voit attribuer un canal selon la disponibilité du spectre en examinant chaque bande de fréquence libre qui offre une meilleure communication possible avec le besoin en bande passante de l'utilisateur.

I.5.5 Partage du spectre (Spectrum sharing)

Repose sur le principe que le spectre est partagé entre des utilisateurs PU et SU selon un ensemble de protocoles servant à éviter les interférences mutuelles.

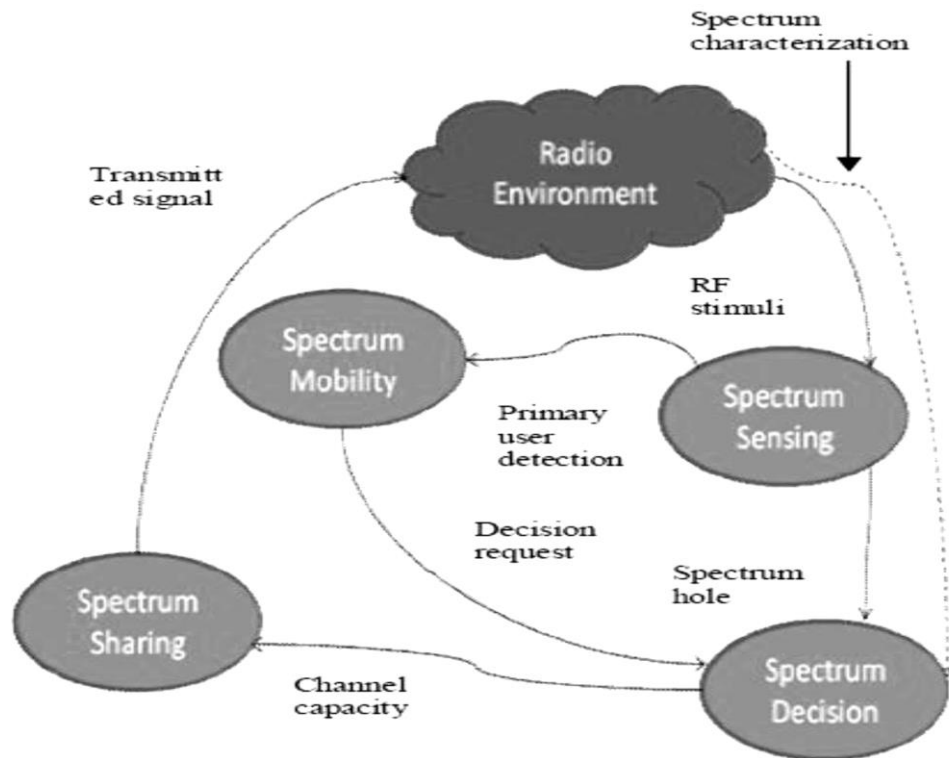


Figure I.3 : Les fonctions de la RC.

I.6 Type de détection de spectre

La tâche principale d'un utilisateur secondaire SU est la détection de spectre dans un réseau RC d'une façon à écouter son environnement donc capter les trous blancs présents et détecter si l'utilisateur principal PU est active ou non sur sa bande, afin qu'il puisse se servir d'un canal libre ou bien de passer à une autre bande d'une manière dynamique et éviter toutes les interférences.

Ce concept est un problème de détection binaire décrit par de deux hypothèses :

$$\begin{cases} H_0 : r(t) = n(t) \\ H_1 : r(t) = h \cdot s(t) + n(t) \end{cases} \quad (I.1)$$

Où H_0 est l'hypothèse d'absence du PU sur le canal considéré et H_1 celle de sa présence.

$r(t)$ est le signal reçu par l'utilisateur SU.

$s(t)$ est le signal transmis par l'utilisateur PU.

$n(t)$ est le bruit et h est le gain du canal.

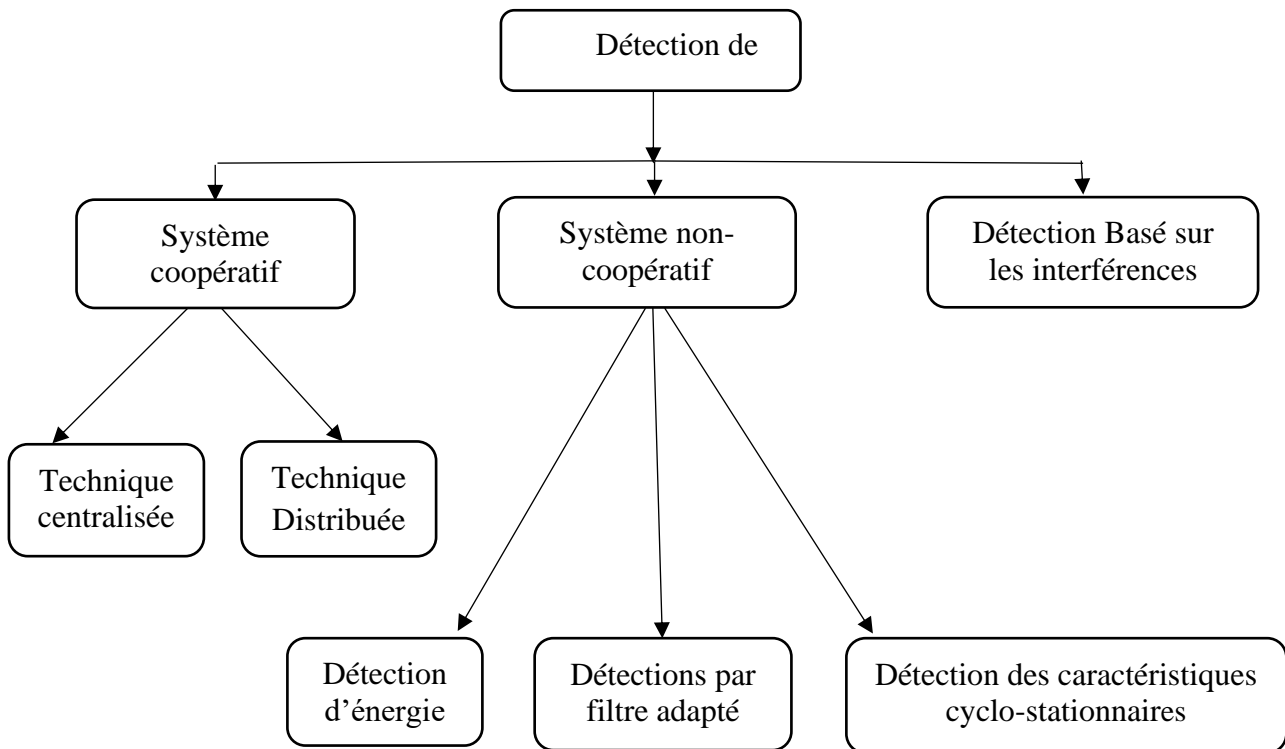


Figure I.4 : Types de détection du spectre.

I.6.1 Détection dans un système non coopératif

C'est une technique dans laquelle l'utilisateur SU détecte le signal d'un usager PU et renseigne sur l'état du canal sans avoir besoin d'autres SU ou bien d'informations externes [1].

I.6.2 Détection d'énergie

Lorsque le SU ne collecte pas assez d'informations sur le PU, une méthode de calcul d'énergie du signal reçu est utilisée, pour ensuite la comparer à un seuil prédéfini.

I.6.3 Détection par filtre adapté

Cette technique de filtrage est utilisée afin de déterminer si le signal PU est actif ou non, l'idée est de faire passer celui-ci par un filtre de façon à pouvoir éliminer le bruit et augmenter l'amplitude de signal utile. La présence d'un pic dans l'amplitude du signal confirme l'existence du PU à cet instant, autrement le PU est absent.

I.6.4 Détection des caractéristiques cyclo stationnaires

L'augmentation de la précision de détection est possible, si seulement si le SU possède les statistiques des informations de la fonction de corrélation du signal de l'utilisateur PU.

I.6.5 Détection dans un système coopératif

L'échange d'informations dans la détection coopérative se fait à travers un canal dédié, où l'ensemble des SU coopère pour augmenter la probabilité de détection et faire face aux problèmes de nœuds cachés. Différentes techniques sont utilisées [6].

I.6.6 La technique distribuée

La présence d'un point central n'est pas nécessaire puisque chaque SU reçoit les détections des usagers SU voisins et les combine avec la sienne pour enfin prendre la décision finale.

I.6.7 La technique centralisée

Les utilisateurs de la radio cognitive sont informés par la méthode de diffusion grâce à l'entité centrale qui rassemble l'ensemble des détections propre à chaque utilisateur secondaire.

I.6.8 Détection basée sur les interférences

La détection basée sur les interférences dépend de la détection du récepteur primaire et de la gestion de la température des interférences.

I.7 Architecture de la RC

La radio cognitive est construite autour de la radio logicielle dans laquelle son architecture englobe un ensemble de composants matériels ou logiciels qui réalisent une série de fonctions et de services.

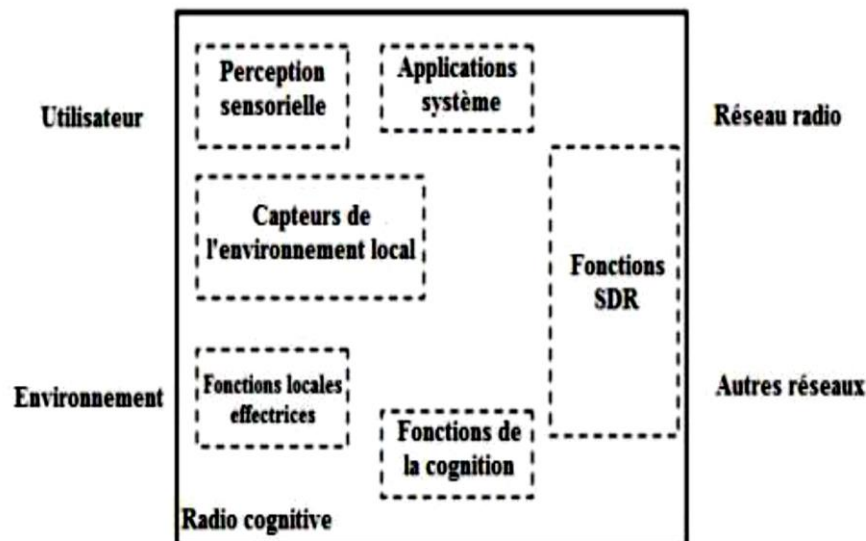


Figure I.5 : Architecture de la radio cognitive.

Les six composantes fonctionnelles de l'architecture d'une RC sont [7]:

- La perception sensorielle de l'utilisateur qui inclut les fonctions de détections et de la perception.
- Les capteurs de l'environnement local.

- Les applications système (les services médias indépendants comme un jeu en réseau).
- Les fonctions SDR (qui incluent la détection RF et les applications radio de la SDR).
- Les fonctions de la cognition (pour les systèmes de contrôle, de planification et d'apprentissage).
- Les fonctions locales effectrices (synthèse de la parole, du texte, des graphiques et des affiches multimédias)

I.8 Cycle de cognition

La cognition fait référence à l'action mentale allant de l'analyse perceptive, en passant par la mémorisation, le raisonnement, les émotions et agir en conséquence. Une RC dispose donc d'un cycle de cognition lui permettant d'observer l'environnement, de s'orienter, de créer des plans, de décider, et puis d'agir [8], comme la figure le montre :

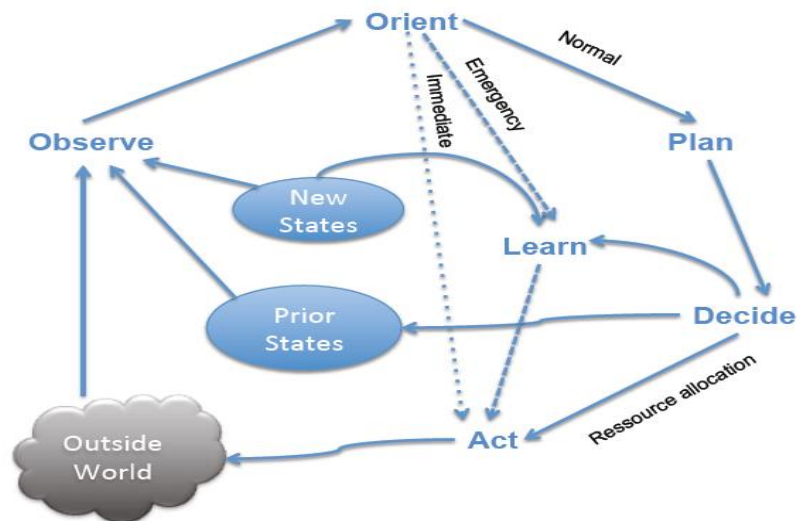


Figure I.6 : Cycle de cognition de Mitola.

- **Phase d'observation (observe)** : Elle définit la perception sensorielle et les capteurs d'environnement local et consiste en la compréhension de l'environnement radio, des besoins des utilisateurs, des contraintes existantes tout en analysant le flux de stimuli entrants.
- **Phase d'orientation** : Elle détermine l'importance d'une observation sous l'effet des stimuli ce qui fait référence à la façon de préciser le besoin d'une action urgente ou bien passer par une planification à long terme.
- **Phase de planification** : Un message entrant engendre la génération d'un plan qui consiste en la prise de décision à long terme.
- **Phase de décision** : sélection d'un plan parmi l'ensemble des plans.
- **Phase d'action** : Exécution du plan choisi précédemment.
- **Phase d'apprentissage** : Quand un nouveau modèle est créé en réponse à une action, l'apprentissage se produit. Ce dernier dépend des phases d'observation, de planification, de

décision et d'action [9], dans les quelles toutes les perceptions sensorielles ainsi que les actions sont continuellement comparées à l'ensemble des expériences antérieures pour en apprendre d'avantage sur l'efficacité d'un mode de communication.

I.9 Applications de la Radio cognitive

Les applications RC sont souvent incluses dans sa définition en raison du caractère impérieux et des applications uniques offertes par celle-ci. Parmi, les applications on trouve :

- Les réseaux sans fil de nouvelle génération ;
- Services de cyber santé (eHealth services) ;
- Réseaux d'urgences ;
- Réseaux militaires.

I.10 Conclusion

Dans ce premier chapitre, nous avons présenté l'approche technologique de la radio cognitive en introduisant son principe, son architecture, ses fonctions de base ainsi que le cycle de cognition suivi pour réaliser de telles fonctions.

Le but d'utilisation de cette technologie durant notre travail est la reconnaissance automatique de type de modulation que nous allons découvrir dans le chapitre suivant.

Chapitre II

**L'AMR dans les systèmes de
communications numériques**

II.1 Introduction

Dans le domaine des réseaux et systèmes de communications numériques une technique de reconnaissance de type de modulation est nécessaire pour la bonne reconstitution du signal émis.

Dans ce chapitre nous allons découvrir le concept de l'AMR et ses domaines d'applications en introduisant des notions sur les modulations numériques telles que QAM et PSK en mettant la lumière sur les modulations d'ordres supérieures.

Dans une autre section le canal caractérisant la propagation de l'onde électromagnétique dans l'espace présente une importance distinctive. Il est donc essentiel d'avoir une connaissance des mécanismes en jeu sur le canal de propagation et de ses interactions avec l'environnement pour pouvoir prédire les conditions et les besoins d'établissement d'une liaison entre l'émetteur et le récepteur en analysant le canal de propagation et ces paramètres qui le caractérisent ainsi que le principe d'évanouissement, les types des canaux et les modèles existants.

En fin nous allons présenter la méthodologie de classification lors d'une reconnaissance automatique de type de modulation et les différents classifieurs existants.

II.2 La reconnaissance automatique de la modulation (AMR)

La reconnaissance automatique de type de modulation (AMR) consiste à identifier le type de modulation utilisée par les utilisateurs primaires au niveau du récepteur d'une chaîne de transmission, d'une manière à déduire si le spectre est libre ou pas dans son canal de fréquence. Cette technique permet l'extraction des caractéristiques définissant le type de signaux reçus pour pouvoir les classifier en réception.




Figure II.1 : Principe de reconnaissance automatique de type de modulation.

II.2.1 Domaine d'application de l'AMR

Applications dans le domaine militaire

La reconnaissance automatique de type de modulation dans les services militaires est utilisée pour la vérification des informations sur un adversaire en interceptant un signal. Le brouillage est la principale mesure pour empêcher la communication entre les unités adverses. Il existe de nombreuses

techniques de brouillage disponibles, cependant, la plus courante repose sur le déploiement de brouilleurs dans le canal de communication et la transmission de signaux de bruit ou de signaux inventés en utilisant le type de modulation d'adaptation qui empêche que le message soit récupéré, il existe deux techniques courantes pour y parvenir. Premièrement, la probabilité de détection peut être réduite si la puissance du signal est inférieure à la puissance du bruit, c'est ce qu'on appelle l'étalement de spectre à séquence directe (DSSS).

Deuxièmement, la détection peut être rendue difficile si le signal est transmis avec une ou plusieurs fréquences alternatives, c'est ce qu'on appelle le spectre étalé à sauts de fréquence (FHSS) [10]. Le principe d'AMR dans le domaine militaire est expliqué dans le schéma suivant :

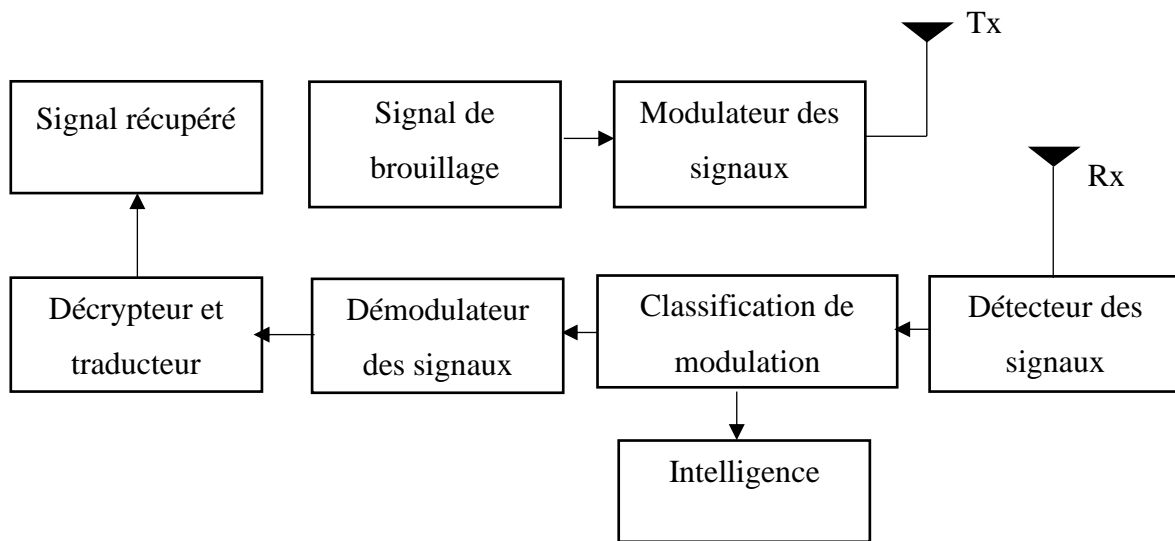


Figure II.2 : schéma d'une communication numérique dans le domaine militaire.

Applications civiles

Dans les systèmes de communication du monde réel, la reconnaissance automatique de type de modulation est largement exploitée dans différents domaines tels que les services médicaux, les sociétés privées et publics... Dans ce cas des modulations d'ordres supérieurs sont utilisées pour une transmission à haut débit de données pour atteindre une efficacité spectrale élevée. La 64-QAM et 256-QAM sont par exemple utilisés pour la télévision numérique terrestre.

Dans le schéma ci-dessous le principe d'une transmission numérique dans le domaine civil est expliqué. D'abord un signal en émission va passer par un codage source et un codage canal ensuite moduler celui-ci selon différentes modulations pour que le signal modulé passe par un canal de propagation. À la réception avant toutes démodulations, une phase de reconnaissance de type de modulation est faite pour ensuite pouvoir classifier les types de modulations utilisées puis les démoduler et récupérer le signal initial.

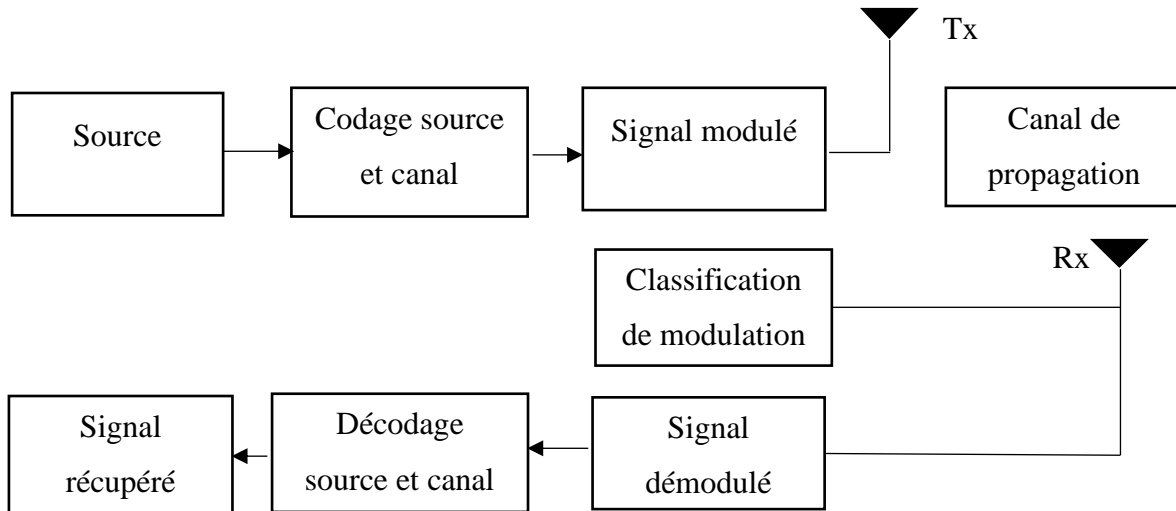


Figure II.3 : Schéma d'une communication numérique dans le domaine civile.

II.2.2 Méthodologie de classification AMR

La classification est la dernière étape lors d'une reconnaissance automatique de type de modulation AMR elle repose sur le principe d'étiquetage des éléments selon leurs classes d'appartenances dont le but est de différencier entre plusieurs signaux reçus.

Les systèmes de classification se déroulent en trois étapes :

- **L'apprentissage** : c'est d'associer de la manière la plus fiable des objets à leurs classes d'appartenances. Il existe deux modes d'apprentissage : supervisé et non supervisé ;
- **La validation** : qui consiste en l'estimation des performances du classifieur ;
- **Le test** : qui consiste à l'évaluation des performances du système de classification.

Parmi les classifieurs les plus couramment utilisés on trouve: machine à vecteur de support (SVM), réseau de neurones artificiels (ANN), K plus proche voisin (KNN).

II.2.3 SVM (Support Vector Machine)

L'émergence des SVMs (Support Vector Machine) traduit par l'appellation de Séparateur à Vaste Marge a commencé autour des débuts des années 1990 par Vladimir Vapnik [11], appartenant à l'algorithme d'apprentissage supervisé issu d'une généralisation des classifieurs linéaires et destiné à résoudre des problèmes de classification.

SVM est une méthode de classification bien adaptée pour traiter des données de très hautes dimensions telles que les textes, les images et la voix...etc. [12].

Un SVM trouve un séparateur linéaire entre les points de données de deux classes différentes, il peut y avoir plusieurs séparateurs possibles entre les classes.

Il existe une infinité d'hyperplans capables de séparer parfaitement les deux classes d'exemples dont le principe des SVMs est de choisir celui qui va maximiser la distance minimale entre l'hyperplan et les exemples d'apprentissage qui est la distance entre l'hyperplan et les vecteurs de support cette distance est appelée la marge, le fait de l'avoir plus large procure plus de sécurité lorsqu'on classe un nouvel exemple.

Parmi les modèles des SVMs, on constate les cas linéairement séparables qui sont les plus simples des SVMs car ils permettent de trouver facilement le classifieur linéaire et les cas non linéairement séparables, ces deux cas sont représentés par les figures suivantes :




Figure II.4 : Cas linéaire de la technique SVM.




Figure II.5 : Cas non-linéaire de la technique SVM.

II.2.4 ANN (Artificiel Neural Network)

Le réseau de neurones artificiels est un modèle de classification, a vu le jour dans les années 1950 dont l'idée inspirée du système nerveux biologique afin d'imiter le fonctionnement du cerveau humain [13]. Ce type de classifieur est largement déployé lors de la reconnaissance des signaux pour ses bonnes performances de classification.

L'architecture principale d'un réseau de neurones se compose de trois couches :

- Couche d'entrée : ensemble des neurones portatifs de donnée à classer envoyer par la suite à la couche masquée.
- Couche cachée : représente la couche intermédiaire entre la couche d'entrée et celle de sortie, qui reçoit les informations de la première couche et le transfert après une série de traitement à la dernière couche.
- Couche de sortie : résultat d'appartenance des données.

Les trois couches vues précédemment sont interconnectées entre eux par des neurones, chaque couche utilisant la sortie de la couche précédente comme entrée de la suivante.

Chaque neurone effectue une tâche dans laquelle il reçoit les informations des neurones de la couche précédente et les utiliser pour calculer sa fonction d'activation d'une manière à ajuster les poids pondérant chaque entrée, voir la figure ci-dessous :




Figure II.6 : Architecture d'un réseau de neurones multicouches.

II.2.5 KNN (k-Nearest Neighbors)

Le classifieur K plus proche voisin (KNN) est l'une des méthodes de classifications les plus anciennes et les plus simples d'apprentissage supervisé [13], utilisée dans des algorithmes d'identification de types de modulations et dans la résolution des problèmes de régressions.

Dans le quel sont définis différentes classes étiquetées avec des données d'entrée sous forme d'un vecteur caractéristique à classifier, comparé à toutes les références des classes possibles.

Le k dans la formule "k plus proches voisins" signifie qu'à la place de se contenter du seul voisin le plus proche de point inconnu, nous pouvons prendre en compte un nombre fixé k où k est une constante définie par l'utilisateur.

Une fois la phase d'apprentissage de l'algorithme réalisée, pour faire une prédiction à partir d'un nouveau point de test, l'algorithme trouve l'observation qui lui est la plus proche.

Ensuite, l'algorithme assigne l'étiquette de la classe la plus fréquente de cette donnée d'apprentissage à la nouvelle observation qui était inconnue.

Nous pouvons faire une prédiction en se basant sur la classe majoritaire et la plus proche sur la base de la distance euclidienne qui est défini par :

$$D = \sqrt{\sum_{i=1}^n |x - y|^2} \quad (\text{II.2})$$

où : x,y sont des vecteurs




Figure II.7 : Exemple d'un classifieur KNN avec K=3 et 7.

Dans cette figure, nous disposons de deux classes de données étoile rouge définie par classe A et triangle vert qui est la classe B, avec un point de test (point d'interrogation inclus dans un carré jaune).

Sur le principe de la technique KNN le point inconnu pourrait être classé soit dans la première classe A ou la seconde classe B selon la valeur de K fixé :

- Si $k = 3$ l'algorithme cherchera les trois voisins les plus proches au point inconnu puis affecté à la classe B car il y a deux triangles et seulement une étoile dans le cercle considéré.
- Si $k = 7$ il sera affecté à la classe A puisque nous avons 4 étoiles face à trois triangles dans le cercle externe.

II.4. Rappels de Notions de communications numériques

II.2.6 Modulation numérique

La modulation numérique est une technique de transformation des signaux de message en bande de base en signaux modulés avec une fréquence supérieure qui joue le rôle d'un porteur dans le but d'améliorer l'immunité du signal contre le bruit, l'efficacité spectrale et l'extension de la portée de transmission. La modulation est appliquée à une porteuse en modifiant l'amplitude, la fréquence ou la phase de cette dernière.

Dans les systèmes de communication du monde réel il existe de nombreux cas où des modulations d'ordres élevées sont utilisées pour une transmission à haut débit de données. L'ordre de modulation d'un schéma de communication numérique est déterminé par le nombre de symboles différents qui peuvent être transmis en les utilisant. Les formes les plus simples des modulations numériques sont de second ordre car elles ne peuvent transmettre que deux symboles, les modulations qui ont un ordre de 4 et plus sont généralement appelées modulations d'ordres supérieurs à savoir la modulation à déplacement de phase M-PSK et la modulation d'amplitude en quadrature M-QAM.

II.2.7 Types de modulations numériques

Il existe une diversité de techniques de modulation selon la nature du message modulant et la porteuse qui représente l'enveloppe de transmission. Les plus utilisées sont les modulations QAM et PSK qui sont développées dans la section suivante.

QAM (Quadrature Amplitude Modulation)

La QAM est une méthode qui résulte de la composition de deux porteuses sinusoïdales déphasées l'une de l'autre de $\pi/2$, dont le principe est de modifier l'amplitude et la phase de la porteuse. Elle est décrite par l'équation ci-dessous [14]:

$$\begin{aligned} s_{QAM}(t) &= \text{Re} \left[(A_{mi} + jA_{mq}) g(t) e^{j2\pi f_c t} \right] \\ &= A_{mi} g(t) \cos 2\pi f_c t - A_{mq} g(t) \sin 2\pi f_c t \end{aligned} \quad (\text{II.10})$$

Où : $m = 1, 2, \dots, M$.

f_c : La fréquence porteuse.

A_{mi}, A_{mq} : Amplitude de signal porteur d'information.

$g(t)$: Signal modulant.

$s_{QAM}(t)$: Signal QAM modulé.

Exemple de constellation de M-QAM avec M=4, 16, 64 :

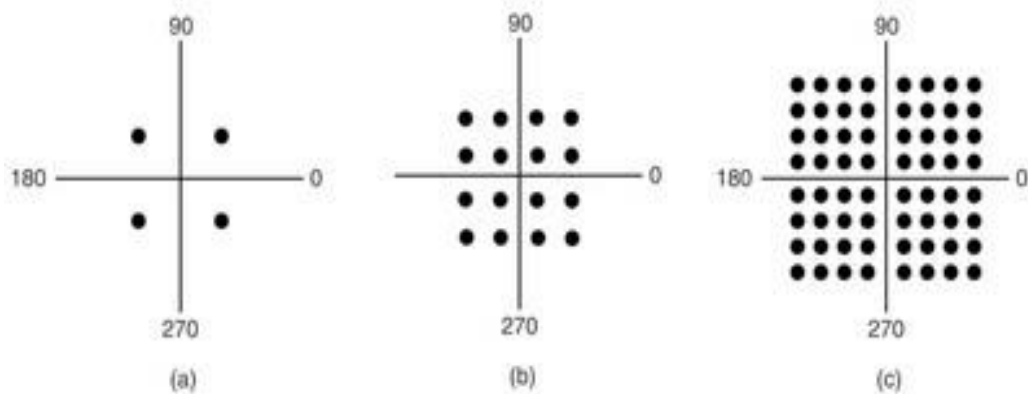


Figure II.8 : Constellation M-QAM

- Constellation 4-QAM avec et sans bruit additif :




Figure II.9 : Constellations 4-QAM.

PSK (Pulse Shift Keying)

La modulation à déplacement de phase représente une forme de modulation numérique dont le principe est de modifier la phase de la porteuse servant pour véhiculer le signal à transmettre.

L'expression du signal PSK est donné par :

$$s_{PSK}(t) = \text{Re}[e^{j(2\pi f_c t + g(t))}] \tag{II.11}$$

$$= \cos(2\pi f_c t + \sum_k a_k h_e(t - kT))$$

Où : f_c : La fréquence porteuse.

T : Période symbole.

a_k : Séquence de symboles.

$g(t)$: Signal modulant.

$s_{PSK}(t)$: Signal PSK modulé.

Exemple de constellation de M-PSK avec M=2, 4, 8 :




Figure II.10 : Constellations M-PSK.

- Constellation 8PSK en présence et en absence du bruit :




Figure II.11 : Constellations 8PSK.

II.2.8 Critères de choix d'une modulation numérique

BER (Bit Error Rate)

Le taux d'erreurs binaire est le nombre de bits erronés sur le nombre de bits envoyé pendant un intervalle de temps étudié qui est exprimé par :

$$BER = \frac{Nb_E}{Nb_T} \tag{II.12}$$

Où : Nb_E : Nombre de bits erronés.

Nb_T : Nombre de bits total transmis.

SNR (Signal to noise ratio)

Le SNR est une mesure qui compare le niveau d'un signal souhaité au niveau de bruit. Il est défini comme le rapport de la puissance d'un signal à la puissance de bruit qui est représenté par l'équation suivante :

$$SNR = \frac{P_{signal}}{P_{bruit}} \quad (II.13)$$

Où : P_{signal} : Puissance du signal.

P_{bruit} : Puissance de bruit.

Efficacité spectrale

L'efficacité spectrale est définie comme étant le rapport entre le débit binaire et la bande passante qui s'exprime en bits/s/Hz, c'est-à-dire le nombre de données binaires envoyé sur une bande fréquentielle allouée, son équation est comme suite :

$$\eta = \frac{D}{B} \quad (II.14)$$

Où : η : Efficacité spectrale.

D : Débit binaire.

B : Bande passante.

II.2.9 Canaux de propagation

Un canal de transmission est un système radioélectrique qui permet de transformer un signal électrique d'émission en un signal électrique de réception par l'intermédiaire d'ondes électromagnétiques. Le champ de transformation des ondes électromagnétiques lors de leur propagation est appelé canal de propagation qui ne tient en compte que des interactions du signal émis avec l'environnement traversé. Voir la figure

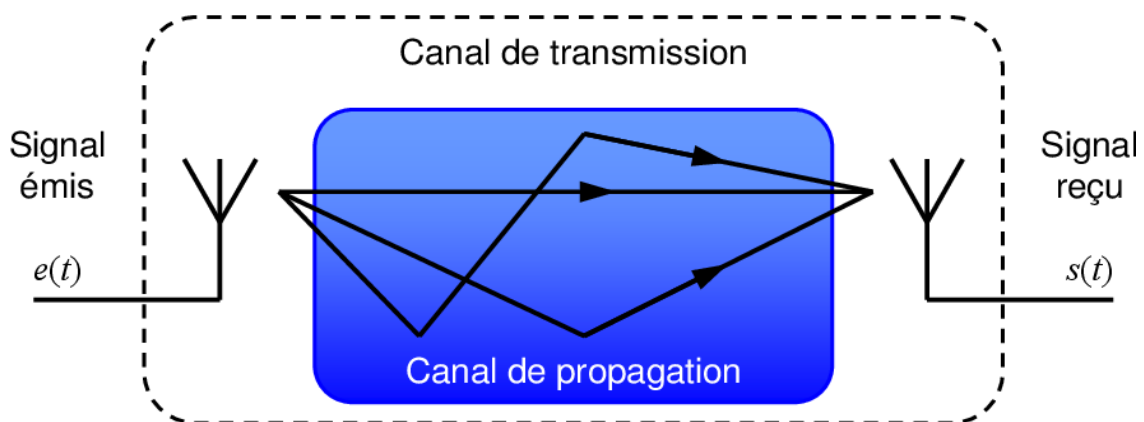


Figure II.12 : Canal de propagation.

II.2.10 Les modèles de canaux de propagations

La conception d'un système de communication performant dépend en grande partie de la précision de la représentation du canal réel, il est utile de modéliser le canal par différentes techniques de classifications. On distingue les deux modèles suivants : modèle déterministe et le modèle statistique.

Modèle déterministe

Les modèles déterministes sont basés sur une description précise de l'environnement de propagation afin de prendre en compte l'influence des obstacles sur la propagation des ondes. Ces modèles ne sont valables que pour des sites où le canal est invariant dans le temps.

Modèle statistique (stochastique)

Les modèles statistiques sont obtenus à partir des mesures de réponses du canal. Les modèles statistiques visent à décrire l'évolution des paramètres du canal par des lois statistiques pour obtenir la représentation la plus réaliste possible du canal. On peut extraire par calcul quelques paramètres caractéristiques, pour ensuite, déterminer les lois statistiques qui caractérisent au mieux la variation de ces paramètres. Citons, par exemple, les lois de Rice ou de Rayleigh qui régissent les variations des amplitudes des trajets.




Figure II.13 : Types de modèles des canaux de propagation.

II.2.11 Caractéristique du canal de propagation

La caractérisation des canaux se fait à partir de certains paramètres permettant de quantifier le canal de propagation. Ces paramètres sont [15] :

Effet Doppler

L'effet Doppler correspond au phénomène physique selon lequel la fréquence d'une onde semble modifiée lorsque la source émettrice de l'onde et/ou l'observateur de l'onde sont en mouvement. L'étalement Doppler est causé par la variation temporelle du canal avec F_d la fréquence doppler, F_c la fréquence de la porteuse, c la vitesse de la lumière et v la vitesse du récepteur. Cet écart est représenté par :

$$F_d = F_c \frac{v}{c} \cos(\theta) \quad (\text{II.1})$$

$$B_d = 2F_{d_{max}} \quad (\text{II.2})$$

Temps de cohérence (cohérence time)

Le temps de cohérence du canal de propagation représente la durée pendant laquelle le canal est considéré comme invariant. Le temps de cohérence T_c et la bande doppler sont inversement proportionnels, il est défini par :

$$T_c = \sim \frac{1}{B_d} = \frac{1}{2} F_{d_{max}} \quad (\text{II.3})$$

Bande de cohérence (cohérence bandwidth)

La largeur de bande de cohérence B_c est une mesure de la différence maximale de fréquence pour laquelle des signaux sont encore fortement corrélés en amplitude.

$$B_c = \frac{1}{\tau_{max}} \quad (\text{II.4})$$

II.2.12 L'évanouissement

Les réseaux de communications sont limités en performances et en capacité principalement à cause de deux facteurs liés au canal de transmission : le bruit et les effets de dispersion du canal de propagation, comme les évanouissements. Ces derniers affectent les signaux émis ce qui mène à la dégradation de la qualité d'information transmise.

Le phénomène d'évanouissement rencontré par un signal propagé dépend de la nature du signal transmis et des caractéristiques du canal. Il existe deux types d'évanouissements qui appartiennent à l'évanouissement à petite échelle qui se manifestent principalement par une dispersion ou étalement du signal dans le temps et la variation du comportement du canal, on trouve : évanouissement dû à la dispersion temporelle qui se décompose en deux catégories : les évanouissements plats et les évanouissements sélectifs en fréquence. L'autre type dû au décalage doppler qui comporte les évanouissements lents et les évanouissements rapides. Contrairement à l'évanouissement à grande échelle qui se concentre sur des grandes espaces qui cause une chute de puissance dû aux obstacles rencontrés [16].

Évanouissements dû à la dispersion temporelle

a. Plat (uniforme)

L'évanouissement uniforme désigne un canal dont lequel la largeur de bande de cohérence est plus grande que la largeur de bande du signal transmis. Toutes les fréquences du signal qui subit de la dispersion sont affectées dans la même proportion donc la dégradation est non sélective en fréquence.

b. Sélectif en fréquence

Le canal est considéré comme sélectif en fréquence lorsque la bande de cohérence du canal est inférieure à la bande occupée par le signal.

Évanouissements dû au décalage doppler

a. Lent

Lorsque les signaux sont affaiblis à cause d'un ombrage entre l'émetteur et le récepteur, nous parlons d'un évanouissement lent. Le canal est alors non sélectif en temps si le temps de cohérence du signal est supérieur à la durée du symbole émis donc la bande occupée par le signal est supérieure au décalage Doppler.

b. Rapide

Nous parlons d'évanouissement rapide lorsque la réponse du canal change rapidement durant la période d'un canal. Il est dû au fait que le temps d'un symbole est supérieur au temps de cohérence du canal.

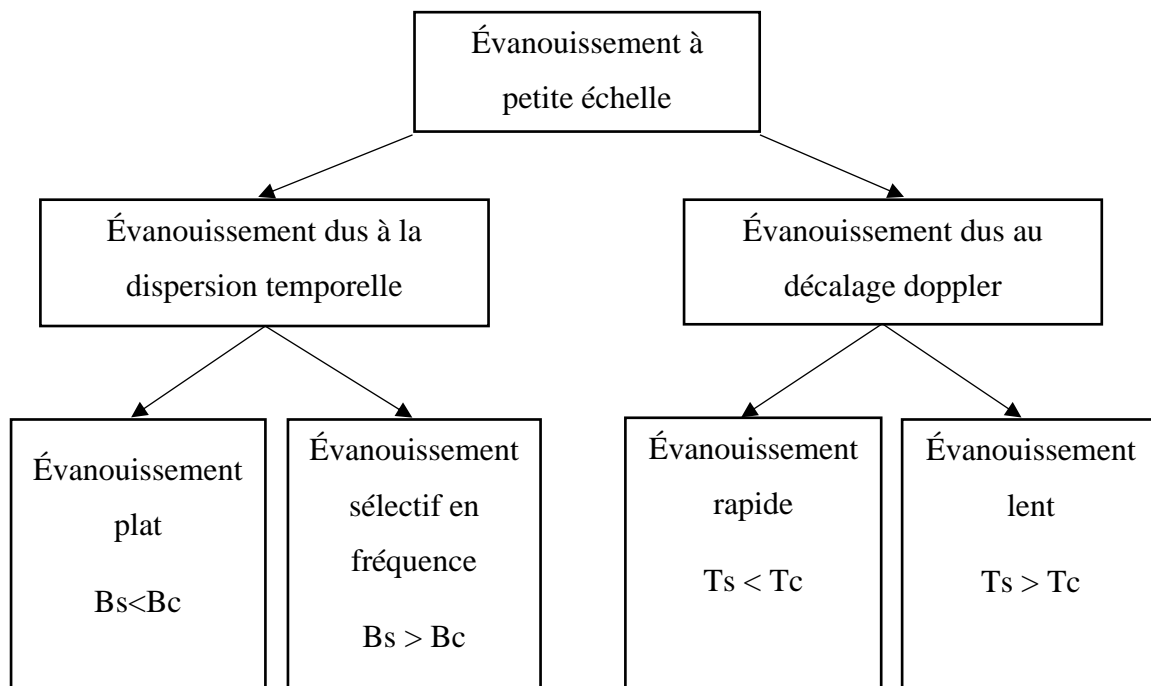


Figure II.14 : Types des évanouissements.

II.2.13 Modèles de canaux de transmission

Les modèles de signaux sont le point de départ de toute stratégie de classification de modulation significative. Dans les systèmes de communications plusieurs canaux modélisent l'environnement de propagation qu'ils soient statistiques ou déterministes pour l'émission des signaux, pour cela des modèles mathématiques bien défini ont été choisi afin de répondre aux besoins de transmission de

signaux de communication. Trois canaux de communication populaires, à savoir le canal de bruit blanc gaussien additif AWGN, le canal Rayleigh et celui de Rice.

Le bruit blanc gaussien additif est l'un des modèles de bruit les plus largement utilisés dans de nombreux problèmes de traitement du signal.

Les canaux de Rayleigh et Rice concernent en grande partie la communication sans fil, où les signaux sont transmis dans des environnements à trajets multiples [14], [17].

Canal Bruit Blanc Gaussien Additif (AWGN)

Le canal AWGN est le bruit de radio statistiquement aléatoire caractérisé par une gamme de fréquence large en ce qui concerne un signal dans un canal de communication qui provient de nombreuses sources telle que les vibrations thermiques. Le bruit blanc gaussien additif est caractérisé par une densité spectrale constante et une distribution d'amplitude gaussienne de moyenne nulle. L'amplitude du signal a une caractéristique unique d'être robuste contre le décalage de phase, décalage de fréquence ou tout type de changement de rotation du signal transmis.

AWGN est souvent utilisé comme modèle de canal qui ne tient pas compte de l'évanouissement et la sélectivité en fréquence, il produit des modèles mathématiques simples, traitables et utiles pour mieux comprendre le comportement d'un système. Ce modèle est une bonne solution pour les liaisons de communication par satellite et des trajets directs uniquement avec signal arrivant en vue directe sur le récepteur, ce qui n'est pas le cas pour les trajets multiples.

Le canal est représenté par un modèle défini par l'équation suivante :

$$y(t) = x(t) + n(t) \quad (\text{II.5})$$

Où :

$x(t)$: Un signal émis.

$n(t)$: Un bruit blanc additif.

$y(t)$: Un signal reçu.




Figure II.15 : Canal AWGN.

Avec : $n(t) \sim \mathcal{N}(\mu = 0, \sigma^2)$.

Le bruit blanc gaussien additif est caractérisé par une distribution gaussienne défini par :

$$y = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \tag{II.6}$$

Où : \mathcal{N} : Densité spectrale du bruit.

μ : sa moyenne.

σ : son écart type.

σ^2 : sa variance.

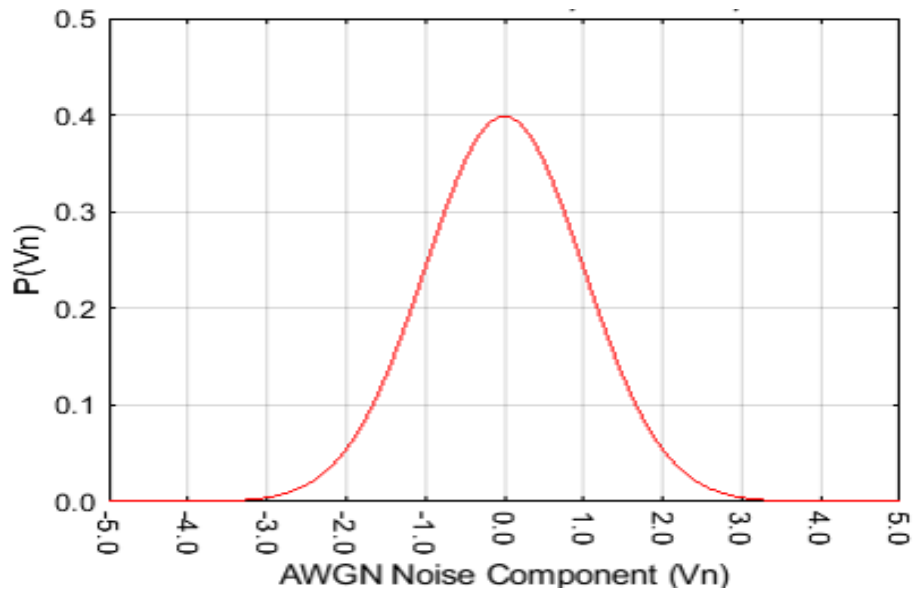


Figure II.16 : Distribution d'un canal AWGN.

Canal de Rice

Ce modèle est souvent utilisé pour caractériser un environnement de propagation avec une vue directe LOS (Line Of Sight) entre l'émetteur et le récepteur, et une multitude de trajets incohérents dûs aux diffuseurs de l'environnement.




Figure II.17 : Propagation multi-trajets LOS.

La densité de probabilité de l'amplitude du coefficient complexe du canal suit une loi de Rice défini par :

$$P(\alpha) = \begin{cases} \frac{\alpha}{\sigma^2} e^{-\frac{\alpha^2+A^2}{2\sigma^2}} J_0\left(\frac{A\alpha}{\sigma^2}\right) & A \geq 0 \quad \alpha \geq 0 \\ 0 & \alpha < 0 \end{cases} \quad (II.7)$$

Avec $K = \frac{A^2}{2\sigma^2}$. (II.8)

Où : α : La distance.

σ^2 : La variance.

J_0 : Fonction de Bessel.

A : Amplitude du trajet direct.




Figure II.18 : Distribution de Rice.

Canal de Rayleigh

Dans les canaux radio mobiles le modèle de Rayleigh est un des canaux de propagation les plus difficiles, mais assez courant en milieux urbains denses, il est couramment utilisé pour décrire des systèmes de transmission en absence d'un chemin direct.

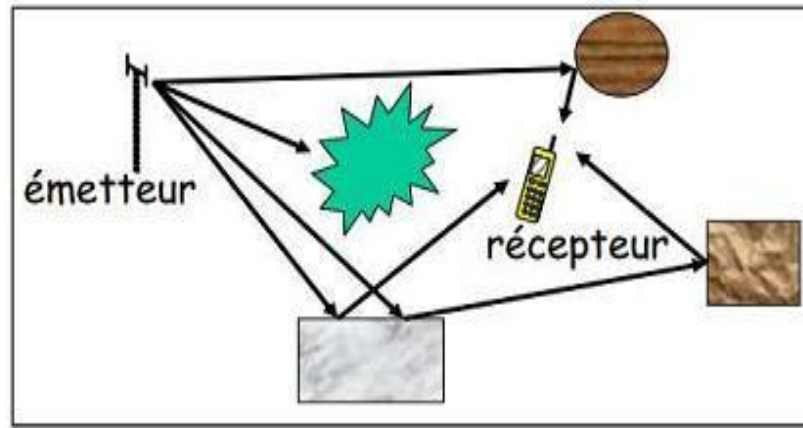


Figure II.19 : Propagation multi-trajets NLOS.

Cette distribution modélise les évanouissements dûs aux multi-trajets incohérents lorsque l'émetteur et le récepteur ne sont pas en vue directe NLOS (Non Line Of Sight). La densité de probabilité de α est une loi de Rayleigh :

$$P(\alpha) = \begin{cases} \frac{\alpha}{\sigma^2} e^{-\frac{\alpha^2}{2\sigma^2}} & \alpha \geq 0 \\ 0 & \alpha < 0 \end{cases} \quad (\text{II.9})$$




Figure II.20 : Distribution de Rayleigh.

II.3 Conclusion

Nous avons étudié dans ce chapitre le principe d'une reconnaissance de type de modulation en utilisant les modulations numériques M-QAM et M-PSK en introduisant les canaux de propagations et ses différentes caractéristiques dans les systèmes de télécommunication avec tous les aspects qui influent sur les performances du canal ainsi que l'effet de multi trajets en passant par l'effet doppler

qui résulte du mouvement relatif de l'émetteur et du récepteur, d'ailleurs nous avons réservé une partie de ce chapitre pour étudier les évanouissements avec ces différents types.

Enfin, nous nous sommes intéressés sur la méthode de classification utilisée dans l'AMR qui nous a permis de tirer les différents types des classifieurs (SVM, ANN, KNN et CNN) utilisés dans les systèmes de communication dans notre cas nous allons faire notre étude sur le classifieur des réseaux de neurones convolutifs en utilisant le Deep Learning qui sera détailler dans le chapitre suivant.

Chapitre III

Notions de Deep Learning

III.1 Introduction

L'intelligence artificielle vise une mécanisation du raisonnement humain c'est-à-dire à inculquer à une machine des facultés de cognition humaine. Le Deep Learning fait partie des algorithmes très puissants de la branche de l'apprentissage artificiel (Machine Learning). Cet algorithme, à l'origine inspiré du neurone biologique [13] est capable de réaliser diverses tâches comme par exemple jouer aux échecs, entretenir une conversation, effectuer une reconnaissance de forme ou encore diverses classifications supervisées ou non supervisées sur la base de réseaux de neurones artificiels.

Un réseau de neurones peut être considéré comme un modèle mathématique de traitement réparti et composé de plusieurs éléments de calcul non linéaires appelé neurones, opérant en parallèle et connectés entre eux par des poids afin d'imiter le fonctionnement du cerveau humain. Les neurones artificiels sont souvent utilisés sous forme de réseaux qui diffèrent selon le type de connections entre les neurones et le nombre de couches appropriées.

Dans ce chapitre nous présentons des notions de Deep Learning où nous donnons le principe des réseaux de neurones artificiels (ANN) sous leurs diverses architectures, en déroulant la méthodologie d'optimisation et d'ajustement d'un modèle choisi selon les données fournies en entrées.

III.2. Rappels et Terminologie

III.2.1. Historique

L'histoire de l'apprentissage machine remonte à 1943, lorsque les mathématiciens et neuroscientistes Walter Pitts et Warren McCulloch ont créé un modèle informatique basé sur les réseaux de neurones du cerveau humain, dans lequel ils ont utilisé une combinaison d'algorithmes et de mathématiques qu'ils ont appelé « logique de seuil » pour s'approcher du processus de pensée.

En 1962 la notion du perceptron a été introduit par Rosenblatt [18] et il a été montré expérimentalement que ce réseau monocouche peut résoudre beaucoup de problèmes mais rapidement délaissés à cause des limitations de ce modèle et du manque de financements.

L'étude des réseaux de neurones artificiels a été reprise dans les années 80 après les travaux de Rumelhart, Hinton et Williams qui traitaient l'algorithme de rétro-propagation pouvant être utilisé pour l'apprentissage des réseaux multicouches. Malgré cette avancée notable, ces nouveaux réseaux n'ont pas connu le succès escompté.

C'est dans les années 2010, que les réseaux de neurones artificiels ont pu enfin avoir des performances accrues avec l'avènement du concept de Deep-Learning (apprentissage profond) grâce à la convergence des facteurs suivants :

- Des réseaux de neurones multicouches ;
- Des algorithmes d'analyse discriminante (dont l'émergence remonte aux années 1980) ;
- Des machines dont la puissance de traitement permet de traiter des données massives ;
- Des bases de données suffisamment grandes, capables d'entraîner des systèmes de grandes tailles.

III.2.2. Intelligence artificielle

L'intelligence artificielle (IA, ou AI en anglais pour *Artificial Intelligence*) est une solution à des problématiques dans le domaine scientifique recherchant des méthodes de résolution des problèmes à forte complexité logique ou algorithmique ayant pour but d'avoir des machines intelligentes, mettant en œuvre un certain nombre de techniques permettant aux machines d'imiter une forme d'intelligence réelle.

Cette notion voit le jour dans les années 1950 grâce au mathématicien Alan Turing [13].

Les domaines d'applications de l'intelligence artificielle sont nombreux. Elle est présente dans les appareils photos des smartphones et en photographie pour détecter des scènes précises. La reconnaissance faciale est une autre technologie rendue possible, elle sert à la reconnaissance et l'identification d'un utilisateur d'un téléphone portable.

L'IA est aussi introduite dans le domaine militaire, financière, médical et les industries. Les grandes entreprises de l'informatique (Microsoft, Facebook, Apple ...) s'appuient ainsi sur l'intelligence artificielle en mettant en place des réseaux de neurones artificiels constitués de serveurs permettant de traiter de lourds calculs en Big Data.




Figure III.1 : Relation Deep Learning/Machine/Learning / IA.

III.2.3. Machine Learning

Machine Learning (apprentissage automatique) tente de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires. Le principe est de développer un modèle de machine en se servant d'un algorithme d'optimisation lui permettant de recevoir des données d'entrée, d'effectuer une série de traitements d'apprentissage à la machine par elle-même, quelle que soit la situation, sans que l'on ait formellement à lui édicter toutes les règles - pour produire des prédictions en sortie avec un minimum d'erreurs.

Les algorithmes d'apprentissage automatique peuvent être classés en divers types [19]:

- *Régression* (régression linéaire, régression logistique) ;
- *Classification* (machines à vecteur de support ; réseaux de neurones, méthode des k plus proches voisins) ;
- *Partitionnement de données* (l'analyse discriminante linéaire, les algorithmes génétiques) ;
- *Réduction de dimensions* (l'analyse en composantes principales).

Dans le domaine du Machine Learning, il existe deux principaux modes d'apprentissages : supervisé et non supervisé. La principale différence réside dans le fait que l'apprentissage supervisé se fait sur la base d'une vérité. En d'autres termes, nous avons une connaissance préalable de ce que devraient être les valeurs de sortie de nos échantillons. Par conséquent, l'objectif de l'apprentissage supervisé est d'apprendre une fonction qui, à partir d'un échantillon de données et des résultats souhaités, se rapproche le mieux de la relation entre entrées et sortie observable dans les données. En revanche, l'apprentissage non supervisé n'a pas de résultats étiquetés, son objectif est de déduire la structure naturelle présente dans l'ensemble des données.

III.2.4. Deep Learning

Un sous-domaine important de l'apprentissage automatique est l'apprentissage en profondeur qui a également ses racines au milieu du XXe siècle.

L'apprentissage profond est basé sur les réseaux de neurones artificiels, composés de milliers d'unités (les neurones) qui effectuent chacune de petites opérations simples au sein du grand réseau.

Les architectures de Deep Learning reposent sur le perceptron comme base des réseaux de neurones, impliquant souvent des ensembles de données volumineux ou massifs. L'apprentissage en profondeur introduit des réseaux de neurones profonds, avec de nouveaux algorithmes et de nouvelles architectures (par exemple, les réseaux de neurones convolutifs CNN, les réseaux de neurones récurrents RNN et les LSTM) [20].

La première couche d'un réseau est appelée couche d'entrée, tandis que la dernière est appelée couche de sortie. Toutes les couches entre l'entrée et la sortie sont appelées couches cachées. Chaque couche est généralement un algorithme simple. Les résultats d'une première couche de neurones servent d'entrée aux calculs d'une deuxième couche et ainsi de suite en formant ainsi notre réseau de neurones.

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données.

Parmi les architectures neuronales les plus utilisées en Deep Learning :

- Les réseaux de neurones profonds (Deep Neural Networks) : Ce sont des réseaux similaires aux réseaux MLP mais avec plus de couches cachées. L'augmentation du nombre de couches, permet à un réseau de neurones de détecter de légères variations du modèle d'apprentissage, favorisant le sur-apprentissage ou sur-ajustement.
- Les réseaux de neurones convolutionnels : Ces réseaux divisent le problème en sous parties, partie convolutive et partie classification.

III.3. Bases des réseaux de neurones

III.3.1. Neurone biologique

Les réseaux de neurones artificiels sont des modèles mathématiques inspirés de la biologie. Ce dernier est composé d'un grand nombre de cellules nerveuses appelées neurones qui représente la brique de base de ce réseau. Il se décompose en trois grandes entités :

- Un corps cellulaire.
- Des dendrites qui représentent les capteurs pour la transmission de l'influx nerveux.
- Un axone est le support qui transporte l'information entre neurones.
- Une synapse est le point de contact entre l'axone d'un neurone et la dendrite d'un autre neurone.

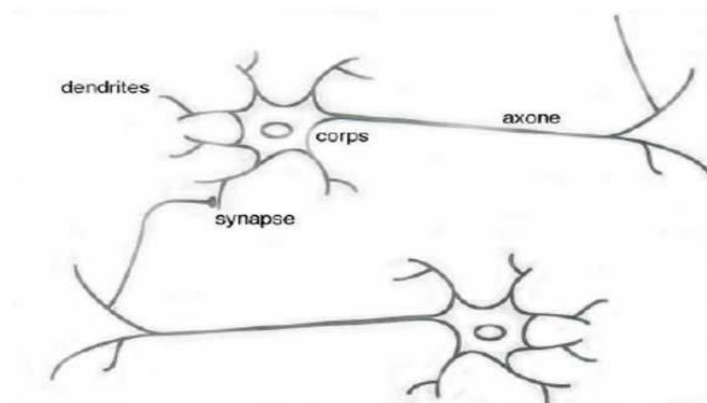


Figure III.2 : Neurone biologique.

Neurone artificiel	Neurone biologique
Poids de connexion	Synapses
Signal de sortie	Axones
Signal d'entrée	Dendrites
Fonction d'activation	Soma

Tableau III.1 : Comparaison entre le neurone biologique et le neurone artificiel.

III.3.2. Perceptron

Le perceptron également appelé perceptron monocouche [18] pour le distinguer d'un perceptron multicouches, est un neurone artificiel qui représente le réseau de neurones à anticipation le plus simple, il repose sur un algorithme d'apprentissage supervisé de classifieurs binaires appelé fonction de seuil qui est une fonction linéaire qui peut décider si une entrée appartient ou non à une classe spécifique.




Figure III.3 : Perceptron monocouche.

D'après la figure ci-dessus une équation est définie :

$$y_1 = f(\sum X_m W_m) + b \tag{III.1}$$

Où W_m : Vecteur de poids réels.

m : Nombre d'entrées du perceptron.

X_m : Entrée du perceptron.

b : Le biais.

La valeur de 0 ou 1 est utilisé pour classer comme instance positive ou négative. Si b est négatif, alors la combinaison pondérée des entrées doit produire une valeur positive supérieure afin de pousser le neurone classifieur au-dessus du seuil 0.

L'algorithme d'apprentissage du perceptron ne se termine pas si l'ensemble d'apprentissage n'est pas linéairement séparable. Si les vecteurs ne sont pas linéairement séparables, l'apprentissage n'atteindra jamais un point où tous les vecteurs sont classés correctement. L'exemple le plus célèbre de l'incapacité du perceptron à résoudre des problèmes avec des vecteurs linéairement non séparables est le problème du ou exclusif booléen.

III.3.3. Réseaux ANN (Artificiel neural network)

Un neurone est l'élément constitutif des réseaux de neurones. En général, chaque neurone reçoit plusieurs entrées, dont chacune provient d'un nœud appartenant à une couche précédente.

ANN se compose d'une couche d'entrée, d'une couche de sortie et d'une ou plusieurs couches cachées [21]. Pour chaque paire de couches adjacentes dans ce réseau, les neurones de la couche gauche sont connectés aux neurones de la couche droite via un bord qui a un poids numérique. Si tous les neurones de la couche gauche sont connectés à tous les neurones de la couche droite, cela s'appelle un MLP (multi-layer perceptron).




Figure III.4 : Réseau de neurones artificiels avec une seule couche cachée.

III.3.3.1. Propriétés des ANN

Les Réseaux de neurones artificiels sont considérés comme des imitateurs du système biologique. Ils se caractérisent par :

- **Le parallélisme** : les ANNs sont constitués à base de neurones simples interconnectés entre eux, dont le but est la réalisation d'un modèle bien défini ce qui rend le traitement de l'information massivement parallèle.
- **Les poids synaptiques** : La pondération des liaisons synaptiques entre les neurones influe sur l'efficacité et la fiabilité du réseau du point de vue rapidité et exactitude des résultats fournis.

- **L'apprentissage** : L'apprentissage est la propriété la plus intéressante des réseaux de neurones, son but est d'arriver à trouver un ensemble de valeurs de connexions afin d'atteindre les résultats voulus.

III.3.3.2. La fonction d'activation

La fonction d'activation est une fonction de transfert qui représente deux types linéaire et non linéaire [22], cette dernière introduit de la non-linéarité dans un réseau de neurones empêchant ainsi une consolidation des couches cachées. Par conséquent, les fonctions d'activations maintiennent la structure des réseaux de neurones et évitent qu'ils ne soient réduits à une couche d'entrée et une couche de sortie. Elle permet de calculer une certaine valeur en fonction des entrées et des poids qui seront transmis à la couche suivante.

Bien qu'il existe de nombreuses fonctions d'activations courantes, dont on peut citer :


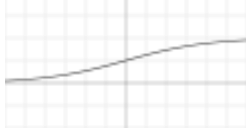


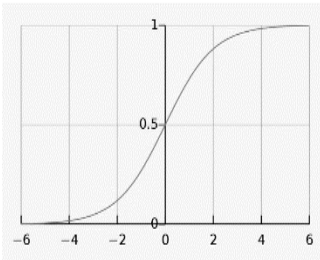
Fonction d'activation	Graphe	Équation
Identité		$f(x) = x$
Logistique (ou marche douce, ou sigmoïde)		$f(x) = \frac{1}{1 + e^{-x}}$
Tangente hyperbolique Tanh(x)		$f(x) = \frac{x}{e^x + e^{-x}}$
Unité de rectification linéaire (ReLU)		$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$
Softmax		$\sigma \left(\begin{matrix} \rightarrow \\ z_i \end{matrix} \right) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$

Tableau III.2 : Les fonctions d'activations.

III.3.3.3. Fonction cout (Cost function)

Afin de trouver un modèle avec un maximum de vraisemblance, l'apprentissage en profondeur cherche les paramètres qui minimisent la fonction cout et quantifient les erreurs effectuées par le modèle. Étant donné que la fonction cout est considérée comme une fonction convexe c'est à dire une fonction qui n'a qu'un seul minimum et de chercher ce dernier avec un algorithme de minimisation appelé gradient descente.

Cette fonction est définie par :

$$L = -\frac{1}{m} \sum_{i=1}^m y_i \log(a_i) + (1 - y_i) \log(1 - a_i) \quad (\text{III.2})$$

Où a_i : La $n^{\text{ième}}$ sortie.

y_i : La $n^{\text{ième}}$ donnée.

m : Nombre de donnée.




Figure III.5 : La fonction convexe.

III.3.3.4. Retro-propagation

Le terme propagation vers l'avant fait référence à la fourniture de valeurs à la couche d'entrée et à la progression à travers les couches cachées vers la couche de sortie qui contient les résultats du passage vers l'avant à travers le modèle [23]. La propagation des erreurs vers l'arrière implique le calcul de nombres qui sont utilisés pour mettre à jour les poids des arêtes dans le réseau de neurones sur la base de l'algorithme gradient descente, cependant deux résultats indésirables peuvent se produire, le gradient de fuite ou le gradient explosif.

Le processus de mise à jour est effectué au moyen d'une fonction de perte (fonction cout), en partant de la couche de sortie la plus à droite puis en se déplaçant de droite à gauche afin d'ajuster les poids w et b de façon à optimiser le modèle. Cette procédure entraîne le réseau de neurones, ce qui consiste à réduire les erreurs des valeurs estimées à la couche de sortie et les valeurs vraies ce qui reflète le principe de l'apprentissage supervisé.

L'équation de la rétro-propagation est définie comme suite :

$$W_{t+1} = W_t - \alpha \frac{\partial L}{\partial W_t} \quad (\text{III.3})$$

Où : W_{t+1} : Paramètre W à l'instant t+1.

W_t : Paramètre W à l'instant t.

α : Pas d'apprentissage positif.

$\frac{\partial L}{\partial W_t}$: Gradient à l'instant t.

➤ Cas d'un réseau formel

le calcul de la descente de gradient dans un perceptron s'effectue par rapport à chaque poids obtenu en sortie de manière simple qui commence par l'initialisation des poids avec des valeurs aléatoires et les propager en combinaison avec les données d'entrées a traves ce réseau, ensuite calculer la variations des poids résultants afin d'ajuster ces paramètres de façon à minimiser les erreurs sachant que l'opération se répète tant que le résultat n'est pas vrai semblant.

➤ Cas d'un perceptron multi-couches

Dans un réseau à plusieurs couches, le calcul du gradient est complexe suite aux nombres de couches cachées mais le principe reste le même, sauf que le calcul d'évolution des poids est effectué pour chaque couche cachée à chaque itération.

III.3.3.5. Architecture d'un réseau ANN

Un réseau de neurones artificiel est un ensemble de neurones interconnectés entre eux par plusieurs topologies [24]. On appelle topologie des réseaux la façon dont les nœuds sont liés entre eux à travers les différentes couches. En général on peut distinguer deux grandes classes de réseaux de neurones artificiels selon leurs architectures :

- Les réseaux à couches (Feedforward)

Feedforward sont des réseaux de neurones dans lesquels l'information se propage vers l'avant de la couche la plus à gauche vers la couche la plus à droite sans retour en arrière.

- Les réseaux récurrents (feedback)

Feedback sont des réseaux de neurones dans lesquels il y a un retour en arrière formant ainsi une boucle avec des états instantanés. Pour cette raison les comportements des réseaux récurrents sont potentiellement plus complexes que ceux des réseaux à couches.

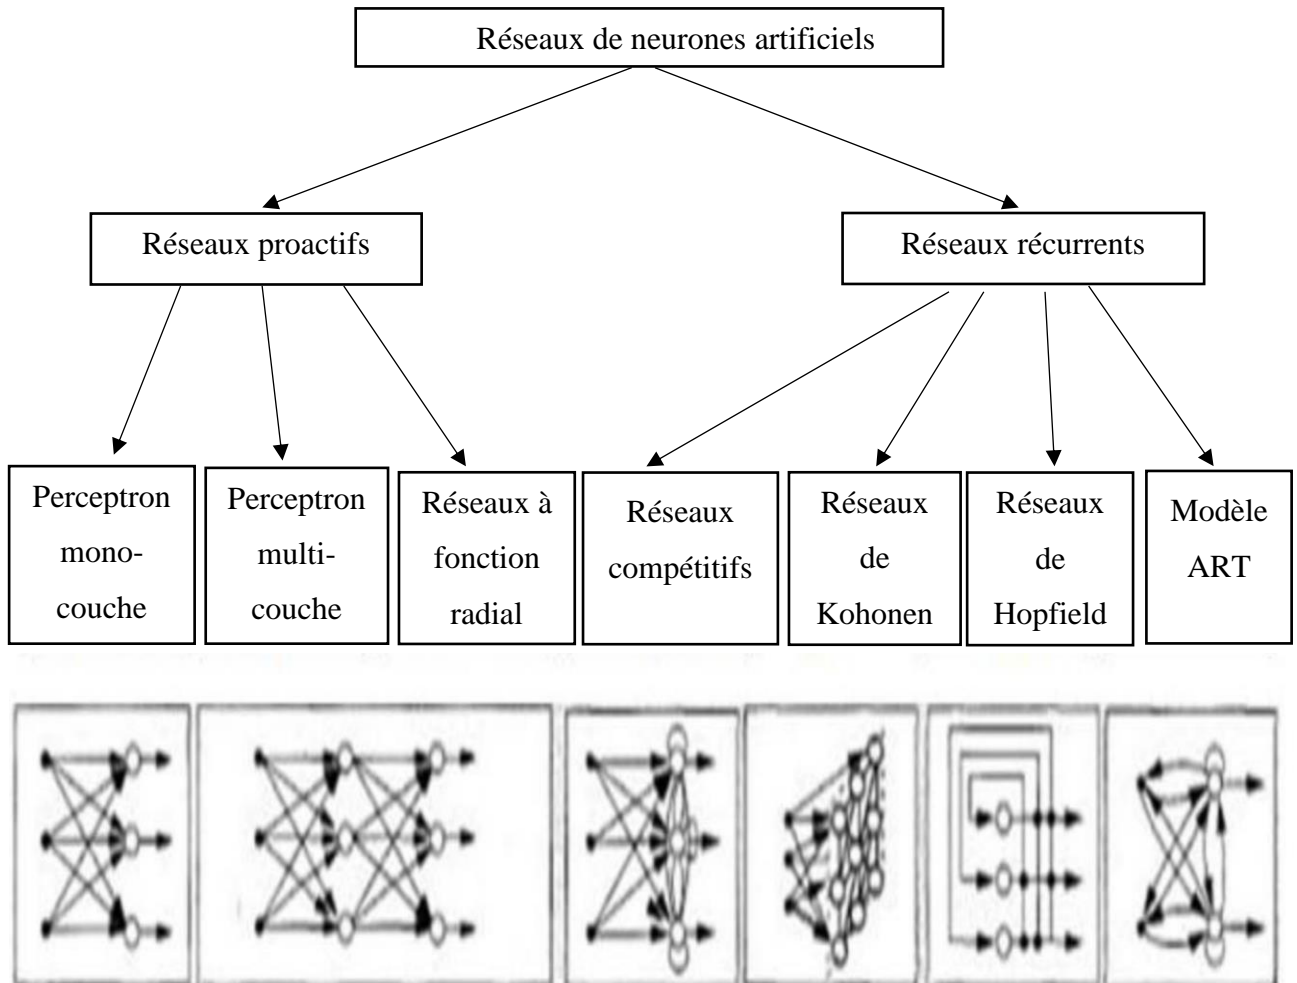


Figure III.6 : Architecture d'un réseau de neurones artificiels.

III.3.3.5.1. Réseaux à couches

Un réseau de neurones feedforward est un réseau constitué d'un ensemble de neurones dans lequel l'information transmise propage vers l'avant à travers toutes les couches [25], dont on peut distinguer:

- Les réseaux simples qui représentent un réseau sans couche cachée, il ne dispose que de deux couches celle d'entrée et une couche de sortie et permet de résoudre des opérations logiques simples. Il est cependant très limité vu qu'il ne peut résoudre que des problèmes linéairement séparables.




Figure III.7 : Réseau sans couche cachée.

- Les réseaux multicouches appelé aussi le perceptron multicouches (MLP) lorsque chaque neurone d'une couche est connecté à tous les neurones de la couche suivante.

Cette architecture est une extension du réseau simple avec une ou plusieurs couches cachées.

Les neurones de la première couche sont reliés au monde extérieur et reçoivent tous le même vecteur d'entrée. Ils calculent alors leurs sorties qui sont transmises aux neurones de la couche suivante. Les sorties des neurones de la dernière couche forment la sortie du réseau.

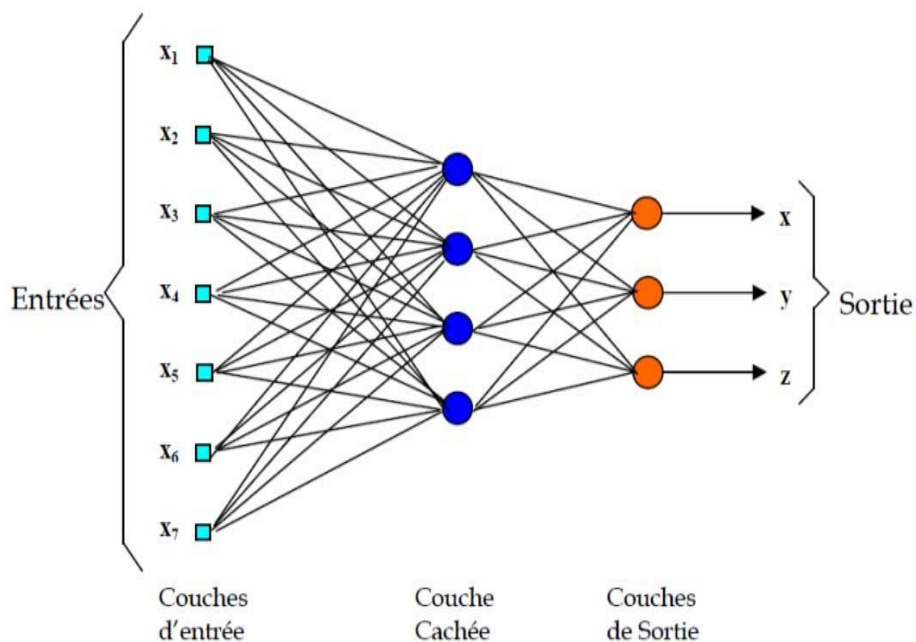


Figure III.8 : Réseau à une couche cachée.

III.3.3.5.2. Réseaux récurrents

Un réseau de neurones bouclé est un type d'architecture développé dans les années 1980 dont la sortie d'un neurone du réseau peut être fonction d'elle-même.

Les RNN conviennent aux ensembles de données séquentielles et complexes, telles que la modélisation du langage, la génération de texte ou la saisie semi-automatique de phrases.

Les matrices de poids des RNN sont mises à jour avec l'algorithme de rétro-propagation dans le temps (BPTT) afin de former le réseau de neurones.

Cependant, il existe un problème appelé le gradient explosif, c'est-à-dire que le gradient devient arbitrairement grand. Une façon de traiter ce problème consiste à utiliser un BPTT tronqué, ce qui signifie que celui-ci est calculé pour un petit nombre de pas au lieu de tous les pas de temps. Une autre technique existe pour surmonter à la fois le problème du gradient explosif et du gradient de fuite est l'utilisation des LSTM.

Les LSTM sont un type spécial de RNN développé en 1997, adaptés pour gérer la dépendance à long terme. Les LSTM sont avec état et contiennent trois portes : porte d'oubliée, porte d'entrée et une porte de sortie.

RNN contient quatre topologies importantes [26] : les réseaux récurrents à couches, les réseaux ART et réseaux de Kohonen et pour finir les réseaux à connexions symétriques (réseaux de Hopfield).




Figure III.9 : Réseau de neurones récurrent.

III.3.3.6. Types d'apprentissages des réseaux de neurones

L'apprentissage est une étape très importante du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du résultat désiré et ceci par l'ajustement des poids et les biais des neurones à une source d'informations bien définie. Il existe deux types d'apprentissages qui sont l'apprentissage supervisé et l'apprentissage non supervisé [27].

❖ L'apprentissage supervisé

Ce type d'apprentissage cherche à imposer au réseau un fonctionnement donné en forçant les sorties des réseaux à prendre des valeurs bien données sur la base d'une vérité. L'apprentissage supervisé signifie que les points de test d'un ensemble de données ont une étiquette qui identifie son

contenu. Par conséquent l'objectif est d'apprendre une fonction qui, à partir d'un échantillon de données et des résultats souhaités, se rapproche le mieux de la relation entre entrée et sortie.

❖ L'apprentissage non supervisé

Appelé aussi apprentissage par compétition ne présente aucun résultat étiqueté et ne dépend que des entrées et pas de la sortie, son objectif est de déduire la structure naturelle présente dans un ensemble de points de données. Les paramètres sont alors déterminés selon un certain critère de conformité du comportement du réseau par rapport à des spécifications générales et non sur des observations.

III.4. Réseau de neurones convolutif

L'une des principales applications de machine Learning est l'analyse d'images qui est une source d'informations majeure sauf que cette opération pose le problème étant chaque image correspond à des données de très grandes tailles, l'idée était d'émerger vers les réseaux de neurones convolutifs.

CNN désigne une sous-catégorie de réseaux de neurones et sont à ce jour un des modèles de classification d'images les plus performants ainsi qu'à d'autres cas d'utilisation [28].

Les réseaux convolutifs sont une forme particulière de réseau neuronal multicouche dont l'architecture des connexions est inspirée de celle du cortex visuel des mammifères.

III.4.1. Architecture des réseaux convolutifs

L'architecture d'un réseau de neurones convolutifs est formée par une succession de blocs de traitements pour attribuer chaque image à sa classe d'appartenance.

L'image se compose de deux dimensions en niveaux de gris, une troisième dimension pour représenter les couleurs fondamentales (Rouge, Vert, Bleu).

Contrairement à un modèle MLP (Multi Layers Perceptron) qui ne contient qu'une partie classification, l'architecture du réseau de neurones convolutif dispose en amont d'une partie convolutive et comporte par conséquent deux parties bien distinctes comme le montre cette figure ci-dessous :

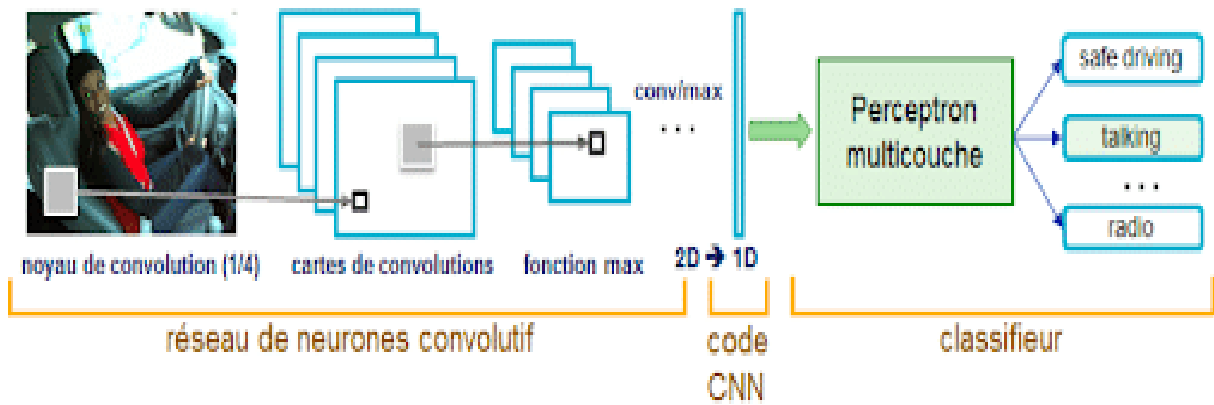


Figure III.10 : Architecture d'un réseau de neurones convolutif.

Une architecture CNN est formée par un ensemble de couches de traitement indépendantes :

- La couche de convolution (CONV) qui traite les données d'un champ récepteur.
- La couche de pooling (POOL), qui permet de compresser l'information en réduisant la taille de l'image intermédiaire
- La couche de correction (ReLU).
- La couche entièrement connectée (FC), qui est une couche de type perceptron.
- La couche de perte (LOSS)

III.4.1.1. Partie convolutive

Le principe est de fournir à l'entrée une image qui va être traitée par chaque couche de façon à extraire ses caractéristiques en la compressant afin de réduire sa taille initiale. Cette image passe à travers une succession de filtres, créant de nouvelles images appelées cartes de convolutions qui sont concaténées dans un vecteur de caractéristiques appelé code CNN. Cette partie est composé de :

a. Couche de convolution

La convolution est une opération mathématique généralement utilisée pour le traitement et la reconnaissance d'images qui implique un ensemble de filtres, qui sont de petites matrices carrées dont les dimensions sont souvent 3x3 mais peuvent aussi être 5x5, 7x7 [29]. La fenêtre de filtre (noyau de convolution) est balayée sur une image de la gauche vers la droite d'un certain nombre de cases défini (le pas) jusqu'à arriver au bout de l'image ou un produit interne est calculé avec le filtre. Le résultat de ce processus d'analyse est appelé une carte de caractéristiques qui contient des nombres réels.

Deux hyper paramètres permettent de dimensionner le volume de la couche de convolution (aussi appelé volume de sortie) : la 'profondeur', le 'pas' et la 'marge'.

- Profondeur de la couche : nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).

- Le pas contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
- La marge (à 0) ou zero padding : la marge est le troisième hyper paramètre qui permet de contrôler le volume de sortie en mettant des zéros à la frontière du volume d'entrée sur le principe d'ajouter une bordure de pixels ayant tous une valeur nulle, dans le but de conserver la même surface que celle du volume d'entrée.

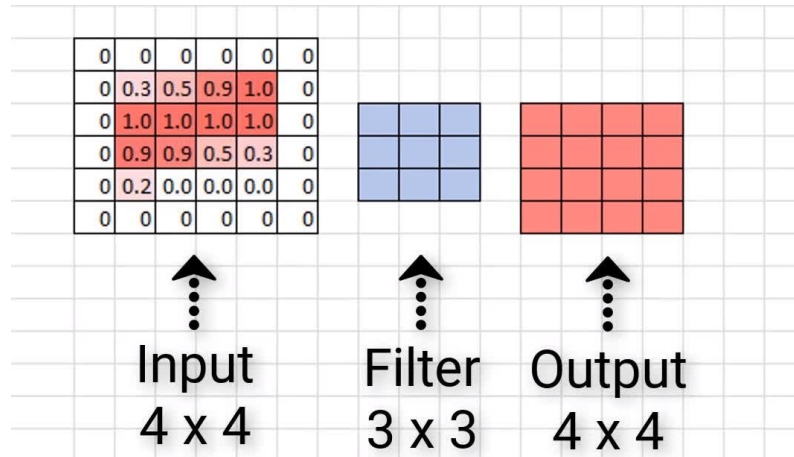


Figure III.11 : Le principe de la marge à zéro.

La formule pour calculer le nombre de neurones du volume de sortie est en fonction de la taille du volume d'entrée W_i , la surface de traitement K (nombre de champs récepteurs), le pas S avec lequel ils sont appliqués, et la taille de la marge P , comme suite :

$$W_0 = \frac{W_i - K + 2P}{S} + 1 \quad (\text{III.4})$$

Si $W_0 \notin \mathbb{N}$, les neurones périphériques n'auront pas autant d'entrée que les autres. Il faudra donc augmenter la taille de la marge (pour recréer des entrées virtuelles). Souvent, on considère un pas $S=1$, on calcule donc la marge de la manière suivante :

$$P = \frac{K-1}{2} \quad (\text{III.5})$$

Dans le cas où le volume de sortie est de même taille que le volume d'entrée, la couche est dite connectée localement.

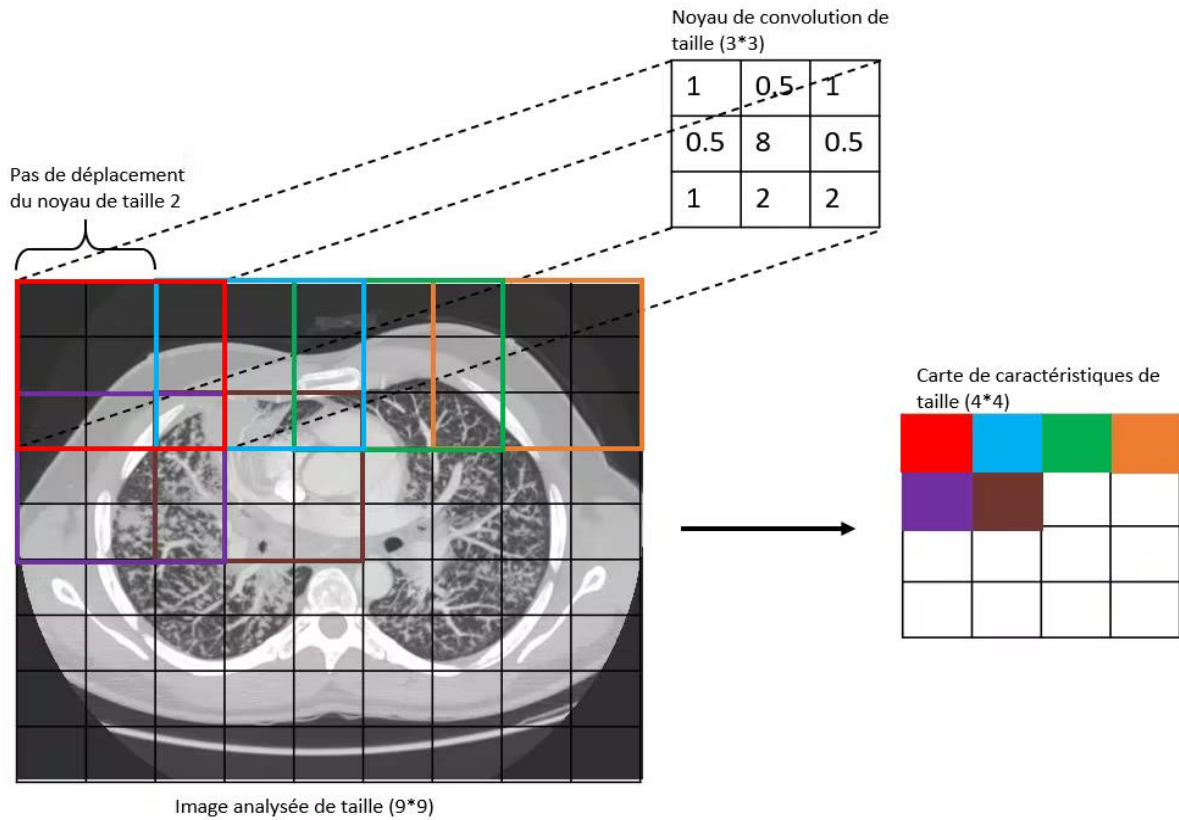


Figure III.12 : Technique de balayage d'image avec filtre convolutif.

b. ReLU (Rectified Linear Units)

La fonction d'activation ReLU est une couche de correction qui sert à l'application d'une fonction non-linéaire aux cartes de caractéristiques obtenues en sortie de la couche de convolution. La non-linéarité facilite l'extraction des caractéristiques complexes qui ne peuvent pas être modélisées par une combinaison linéaire. Cette couche remplace toutes les valeurs négatives reçues en entrées par des zéros. ReLU est définie par l'équation suivant [30] :

$$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases} \tag{III.6}$$




Figure III.13 : La fonction d'activation ReLU.

c. Dropout

La couche d'abondant dite dropout est un moyen d'éviter le sur-apprentissage (overfitting), en empêchant la contribution de certains neurones vers la couche suivante.

d. Pooling

La couche de Pooling est une opération généralement appliquée entre deux couches de convolution [31]. Celle-ci reçoit en entrée les cartes de caractéristiques (features maps) formées en sortie de la couche de convolution afin de réduire la taille des images tout en préservant leurs caractéristiques les plus essentielles.

De plus, son intérêt est qu'il réduit le coût de calcul en réduisant le nombre de paramètres à apprendre et fournit une invariance par petites translations.

Parmi les plus utilisés, on retrouve le max-pooling dont l'idée est de partitionner la carte des fonctionnalités mise à jour en rectangles 2x2 et sélectionner la plus grande valeur de chacun de ces rectangles ou encore l'average pooling dont l'opération consiste à conserver à chaque pas, la valeur moyenne de la fenêtre de filtre, voir la figure ci-dessous :




Figure III.14 : Technique de pooling.

III.4.1.2. Partie classification

Le code CNN obtenu en sortie de la partie convolutive est fourni en entrée dans une deuxième partie de classification, constituée de couches entièrement connectées appelées fully connected (FC) ou perceptron multicouche (MLP) qui sont placées en fin d'architecture.

Après avoir reçu un vecteur en entrée, la couche FC applique successivement une combinaison linéaire puis une fonction d'activation dite Softmax [32], elle renvoie enfin en sortie un vecteur de taille N correspondant au nombre de classes dans lequel chaque composante représente la probabilité pour l'input image d'appartenir à une classe.

La couche de perte est la dernière couche du réseau, elle calcule l'erreur entre la prévision du réseau et la valeur réelle.

a. Couche entièrement connectée

La couche entièrement connectée, en anglais dite fully connected (FC) ; est la première étape dans la partie classification, les neurones dans une couche entièrement connectée ont des connexions vers toutes les sorties de la couche précédente qui représente le code CNN.

b. Softmax

La fonction d'activation Softmax attribut des probabilités décimales dans chaque classe à un problème multi-classe dont la somme des probabilités égale à 1. Cette fonction est représentée par [33] :

$$\sigma \left(\begin{matrix} \rightarrow \\ z_i \end{matrix} \right) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (\text{III.7})$$

Où : σ : Fonction Softmax ; $\begin{matrix} \rightarrow \\ z_i \end{matrix}$: Vecteur d'entrée ; K : Nombre de classes.

e^{z_i} : Fonction exponentiel normalisé du vecteur d'entrée.

e^{z_j} : Fonction exponentiel normalisé du vecteur de sortie.




Figure III.15 : La fonction d'activation Softmax.

c. Couche Loss

La couche de perte est la dernière couche dans le réseau. Elle évalue l'écart entre les prédictions réalisées par le réseau de neurones et les valeurs réelles des observations utilisées pendant l'apprentissage. Plus le résultat est minime plus le réseau de neurones est performant.

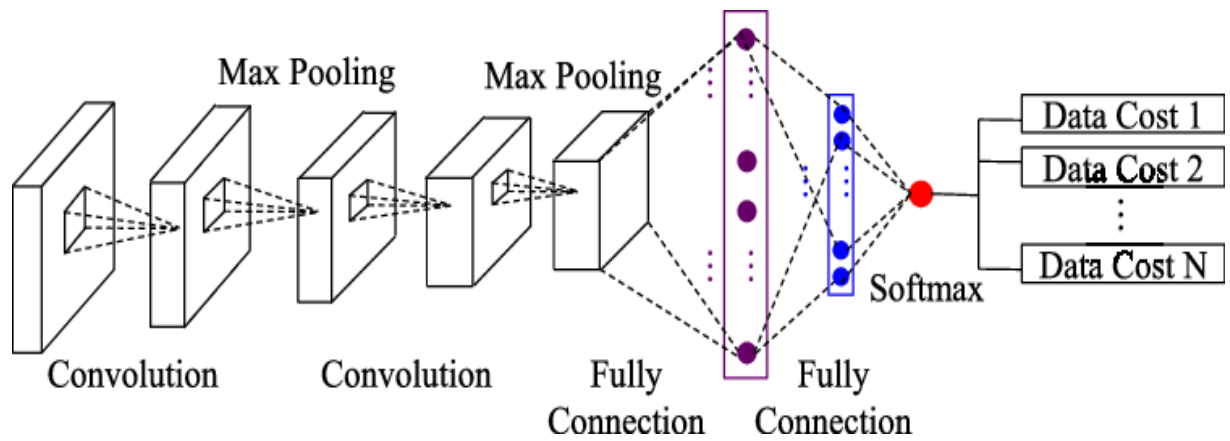


Figure III.16: : Partie classification d'un CNN.

III.4.2. Types d'architectures CNN

- Le NET : première architecture CNN la plus ancienne et largement utilisée, développé en 1988 par Yann LeCun, Corinna Cortes et Christopher Burges, utilisé pour des problèmes de reconnaissances des chiffres manuscrits. Elle se compose de 5 couches de convolutions suivies de deux couches entièrement connectées FC (Le Net-5). Sa simplicité la rendue d'actualité et continue d'être utilisée.
- Alex Net : introduite par Alex Krizhevsky, Ilya Sutskever et Geoff Hinton, ce réseau qui a popularisé le réseau de neurones convolutifs similaire à Le Net mais plus profond et comporte des couches convolutifs empilées. Il a été conçu pour être utilisé avec un ensemble de données d'images à grande échelle. Elle se compose de 5 couches convolutives, 3 couches FC et 2 couches d'abandon.
- VGGNet : développé par Karen Simonyan et Andrew Zisserman, représente un CNN à 16 couches, il peut prendre des grandes images d'entrées de taille 224×224 pixels.
- ResNet : architecture CNN développé par Kaiming He, ce réseau compte 152 couches donc un grand volume de paramètres. ResNet est efficace sur le plan informatique et peut être augmentée ou réduite pour correspondre à la puissance de calcul des GPU.

III.4.3. Paramètres convolutifs

Afin de réaliser une architecture CNN, un choix de paramètres bien précis est pris en considération tels que :

- Le nombre de filtre : il est important de choisir le nombre de filtre adéquat à l'architecture choisi, sachant que la taille des images diminue avec la profondeur du traitement donc les couches les plus proches de sortie nécessitent plus de filtres par rapport à celle d'entrée.
- La forme de filtre : les formes de filtre varient selon le besoin, ils sont généralement choisis en fonction de l'ensemble de données. Les meilleures formes des filtres utilisés sur les images

de MNIST (28x28) sont de taille 5x5 sur la première couche, alors que pour des données d'images avec des centaines de pixels la taille des filtres est de 12x12. Le défi est donc de trouver la forme la plus optimale qui répond aux besoins des données d'entrées à traiter.

- La forme de max-pooling : la taille la plus utilisée est de 2x2. Mais avec présence de grandes quantités de données, engendrent l'utilisation de la forme 4x4 dans les premières couches, ce qui cause la réduction de la dimension du signal et la perte d'information.

III.4.4. Avantages de CNN

Les réseaux de neurones convolutionnels présente plusieurs avantages :

- Un avantage majeur des réseaux convolutifs est l'utilisation d'un poids unique associé aux signaux entrant dans tous les neurones d'un même noyau de convolution.
- Amélioration des performances.
- La robustesse et l'insensibilité à distorsion ou à d'autres changements optiques.
- Les couches de convolutions réduisent considérablement les besoins de stockage.

III.4.5. Applications des CNN

- La reconnaissance automatique de type de modulation : dans un système de transmission la connaissance de type de modulation est la base de l'extraction du message transmis.
- La reconnaissance faciale : identifier des visages sur une photo malgré les facteurs externes.
- Analyse des documents : permet à une machine d'analyser l'écriture d'un individu puis la comparer à une vaste base de données.
- Comprendre le climat : lutte contre le changement climatique pour comprendre les raisons et d'avoir d'information approfondie.
- Les besoins médicaux : prédiction des tumeurs ou d'anomalies ainsi que pour l'élaboration des diagnostics complexes et de traitement à suivre.

III.5. Conclusion

Dans ce chapitre, nous avons introduit les notions de base du Deep Learning ainsi que les définitions essentielles relatives aux réseaux de neurones. Nous avons notamment distingué entre les réseaux de neurones non bouclés qui réalisent des fonctions non linéaires et ceux bouclés avec une conservation d'état. Nous avons aussi mis l'accent sur l'utilisation de réseau de neurones convolutif, son architecture et sa puissance de classification que nous allons utiliser pour la réalisation de notre modèle pour la reconnaissance AMR qui sera détaillée dans le prochain chapitre.

Chapitre IV

**Simulations AMC à base
d'un réseau CNN**

IV.1 Introduction

La classification automatique de type de modulation est un domaine en évolution rapide de l'analyse des signaux qui présente une grande importance dans les applications civiles et militaires.

L'AMR est considérée comme une tâche primordiale permettant au récepteur de démoduler le signal transmis et de récupérer l'information souhaitée. Il y a cependant deux raisons principales pour connaître le type de modulation correcte d'un signal, l'une est pour préserver le contenu des informations du signal et l'autre pour décider de l'action appropriée comme le brouillage.

Dans ce dernier chapitre, nous allons simuler cinq types de signaux de modulation numérique à savoir BPSK, QPSK, 8-PSK, 16-QAM et 64-QAM sur la base de Deep Learning en utilisant les réseaux de neurones convolutionnels CNN avec le logiciel MATLAB. D'abord nous allons générer un certain nombre de données qui vont être entraînées, testées et classifiées selon le modèle de réseau choisi avec plusieurs niveaux du SNR.

IV.2 Classification de types de modulations à base des réseaux de neurones convolutifs

Avec le développement de l'intelligence artificielle, le Deep Learning s'est émerger et appliqué dans plusieurs domaines, dans notre cas la reconnaissance de types des signaux de modulations avec l'utilisation des réseaux de neurones convolutifs CNN. Ce réseau représente l'un des classifieurs les plus performants avec une précision importante, que nous allons s'en servir pour la simulation de notre programme et étudier la performance du modèle choisi en faisant référence aux métriques d'évaluations.

IV.3 Environnement de travail

MATLAB (Matrix Laboratory) est une plate-forme de programmation développée par la société MathWorks, conçue spécifiquement pour les ingénieurs et les scientifiques à fin d'analyser et de concevoir différents systèmes. Le langage MATLAB est un langage matriciel permettons l'expression la plus naturelle des mathématiques computationnelles. Les applications Matlab vous permettent de tester différents algorithmes sur vos données et itérer jusqu'à obtenir les résultats attendus. Ce logiciel présente des ToolBoxs développés par des professionnelles, testées et entièrement documentés afin de faciliter l'utilisation dans divers domaines.

IV.4 Évaluation des performances de classifieur

L'évaluation des performances dans un réseau est une étape importante lors de chaque classification, elle permet de décrire parfaitement les résultats obtenus et d'étudier la qualité d'un outil de classification dans l'étape de test. Pour cela plusieurs indicateurs permettent de mesurer la performance, la comparaison et la validation des algorithmes de classification des modèles. Chacun

de ces derniers à ses spécificités et avec la combinaison d'un ensemble de métriques, une vision complète du modèle est atteinte.

IV.4.1 La matrice de confusion

Dans sa forme la plus simple, une matrice de confusion (également appelée matrice d'erreurs) est un type de tableau de contingence à deux lignes et deux colonnes, chaque ligne correspond à une classe prédite, tandis que chaque colonne correspond à une classe désirée, elle contient le nombre de faux positifs, de faux négatifs, de vrais positifs et de vrais négatifs. Les quatre entrées d'une matrice de confusion de sa forme la plus simple 2x2 peuvent être étiquetées comme suite : TN FN TP FP [34]. Les valeurs diagonales de cette matrice sont correctes, tandis que les valeurs hors diagonale sont des prédictions incorrectes.

		<i>Classes réelles</i>	
		1	2
<i>Classes prédites</i>	1	True positive	False positive
	2	False négative	True négative

Figure IV.1 : Matrice de confusion.

A partir de la matrice de confusions diverses indicatrices de performance sont extraites et résumés pour caractériser les différents classifieurs. Nous en résumons certains dans le tableau ci-dessous :

Métriques d'évaluation	Définition
Exactitude (Θ)	$\frac{V_P}{V_P + F_P + V_N + F_N}$
Rappel (Ψ)	$\frac{V_P}{V_P + F_N}$
Précision (δ)	$\frac{V_P}{V_P + F_P}$
Spécificité (Φ)	$\frac{V_N}{V_N + F_P}$

Tableau IV.1 : Métriques de performance d'un classifieur.

IV.4.2 La courbe ROC (Receiver Operating Characteristic)

La ROC est une courbe qui trace le TPR par rapport au FPR qui représente le taux de vrais positifs par rapport au taux de faux positifs. Cette métrique est utilisée pour la comparaison visuelle des modèles de classification qui montre le compromis entre le taux de vrais positifs et le taux de faux positifs. L'aire sous la courbe ROC est une mesure de la précision du modèle. Lorsqu'un modèle est plus proche de la diagonale, il est moins précis et le modèle avec une précision parfaite aura une aire de 1. Cette représentation met en évidence un autre indicateur d'évaluation pertinent déployé pour mesurer la performance d'un classifieur, appelé l'aire sous la courbe (AUC) [35].




Figure IV.2 : Interprétation de la courbe ROC.

IV.5 Méthodologie de simulation

Notre simulation consiste à traiter les performances de classifieur CNN pour l'identification des modulations avec différentes valeurs SNR. La première phase consiste à générer des trames de données aléatoires pour les cinq types de modulations utilisés, qui vont être introduite comme entrées pour notre classifieur. Par la suite ces données sont réparties en trois catégories, un pourcentage de 80% pour l'entraînement, 10% pour la validation et 10% pour la phase de test afin d'optimiser l'apprentissage et l'exploitation du modèle. Dans la dernière phase, après avoir obtenu des résultats des prédictions, nous allons utiliser la matrice de confusion pour visualiser les erreurs commises lors de la classification.

Le schéma suivant illustre l'enchaînement suivi :

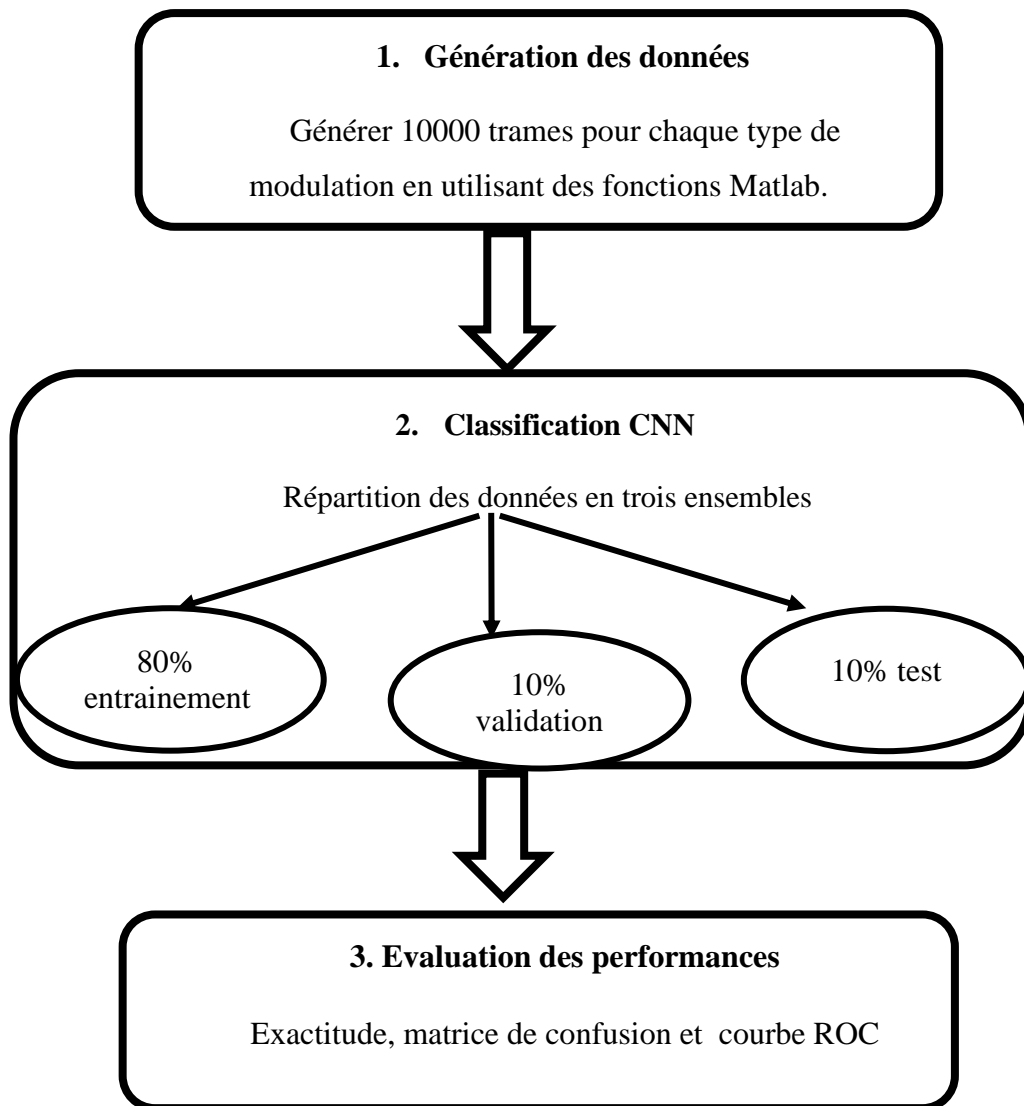


Figure IV.3 : Méthodologie de simulation.

Nous avons d'abord simulé cinq types de modulation à savoir BPSK, QPSK, 8-PSK, 16-QAM, 64-QAM avec un nombre de bits qui égale à 8 bit/symbole et 1024 échantillons/ trame pour des SNR= {-15, 0, 15, 30} en utilisant la commande ci-dessous :

```

modulationTypes = categorical(["BPSK", "QPSK", "8PSK", ...
    "16QAM", "64QAM"]); %déclaration des cinq types de modulations
sps = 8; % nombre d'échantillons par symbole
spf = 1024; % nombre d'échantillons par trame
symbolsPerFrame = spf / sps; %nombre de symboles par trame
  
```

Figure IV.4 : Déclaration des modulations.

Ensuite nous avons défini trois canaux de propagations à savoir le canal AWGN, Rice et Rayleigh dans lesquels les trames vont être envoyées après leurs modulations, nous avons défini un nombre de

trames qui égale à 10000 trames pour chaque type de modulation soit 50000 données au total en utilisant des fonctions intégrées de matlab, ces données sont réparties en trames d'entraînement, de validation et de test à l'aide de cette commande :

```
numFramesPerModType = 10000; % définir 10000 trames par chaque type de modulation
percentTrainingSamples = 80; % affecter 80% pour l'entraînement
percentValidationSamples = 10; % affecter 10% pour la validation
percentTestSamples = 10; % affecter 10% pour le test
```

Figure IV.5 : Répartition des pourcentages.

Par la suite nous avons généré les trames de données avec la fonction « helpModClassGetSource » en choisissant l'emplacement de celle-ci afin de pouvoir faire appel à ses dernières pour la deuxième phase de classification.

```
dataSrc = helperModClassGetSource(modulationTypes(modType), sps, 2*spf);
modulator = helperModClassGetModulator(modulationTypes(modType), sps, fs);
```

Figure IV.6 : Génération des données.

```
dataDirectory = fullfile(tempdir, "ModClassDataFiles");
% choisir l'emplacement des données à générer

disp("Data file directory is " + dataDirectory)% afficher l'emplacement choisi
fileNameRoot = "frame";
```

Figure IV.7 : Sauvegarde des données.




Figure IV.8 : Les trames générées.

Par la suite les trames de chaque type de modulation vont être appelées par la commande « readall » en précisant les trames d'entraînement et de validation ainsi que leurs étiquettes et faire intervenir notre modèle des réseaux de neurones convolutifs en définissant 12 époques d'itérations sachant qu'une époque représente 156 itérations et 256 mini lots de normalisation comme suite :

```
modClassNet = helperModClassCNN(modulationTypes, sps, spf);
maxEpochs = 12; % le nombre d'époques
miniBatchSize = 256;
```

Figure IV.9 : Appel du modèle.

En utilisant les formes d'ondes générées comme données d'apprentissage, nous allons entraîner le modèle des réseaux de neurones convolutifs pour la classification des modulations ainsi que les trames de validation pour confirmer les résultats d'apprentissage.

```
% lancer l'entraînement
trainedNet = trainNetwork(rxTrainFrames, rxTrainLabels, modClassNet, options);
```

Figure IV.10 : Entraînement CNN.

Par ailleurs les trames et les étiquettes de test vont être intervenues afin de les utiliser lors de classification.

Vers la fin une phase de classification est faite en utilisant le modèle choisi et les trames de test pour l'évaluation des performances du classifieur en calculant son taux de classification pour chaque SNR

et cela en comparant les résultats de prédiction par rapport aux étiquettes de chaque type de modulation.

```
% classification
[rxTestPred,score] = classify(trainedNet,rxTestFrames);
testAccuracy = mean(rxTestPred == rxTestLabels);
% afficher le taux de classification
disp("Test accuracy: " + testAccuracy*100 + "%")
```

Figure IV.11 : Classification des modulations.

IV.5.1 Réseau de neurone utilisé

Notre modèle de classification est composé de :

- Une couche d'entrée.
- 6 couches de convolutions, chaque une est suivie d'une couche de normalisation par lots, d'une couche d'activation ReLU et d'une couche de max pooling à l'exception de la dernière dans la quel le max pooling est remplacé par average pooling.
- Une couche entièrement connectée.
- Une fonction d'activation Softmax.
- Une couche de sortie.

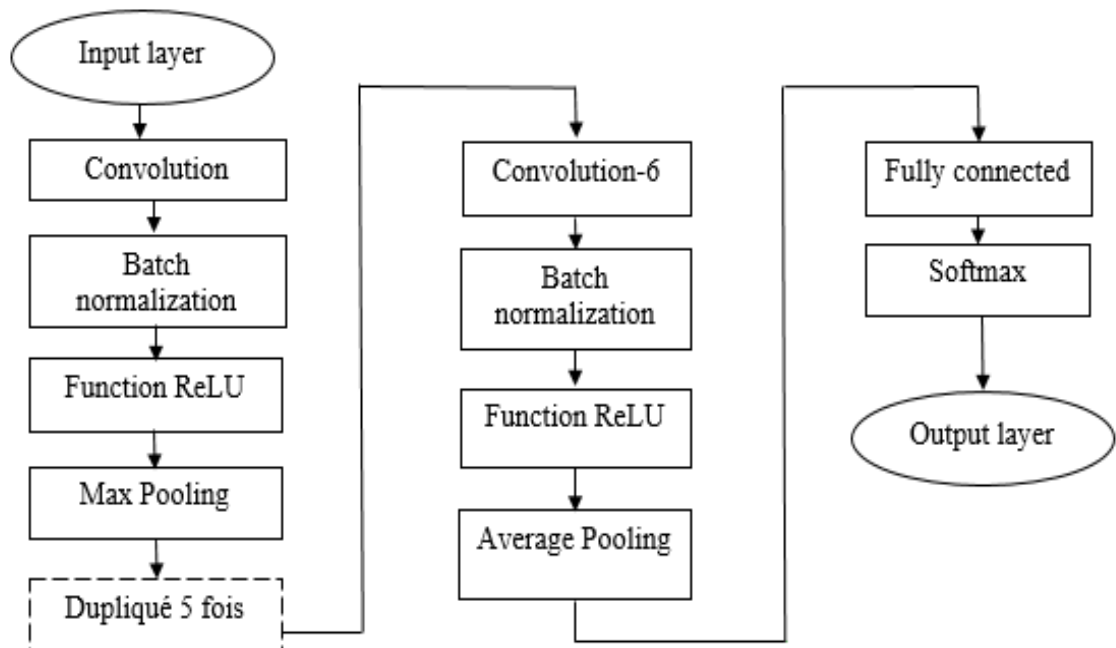


Figure IV.12 : Architecture du modèle CNN utilisé.

IV.5.2 Simulations

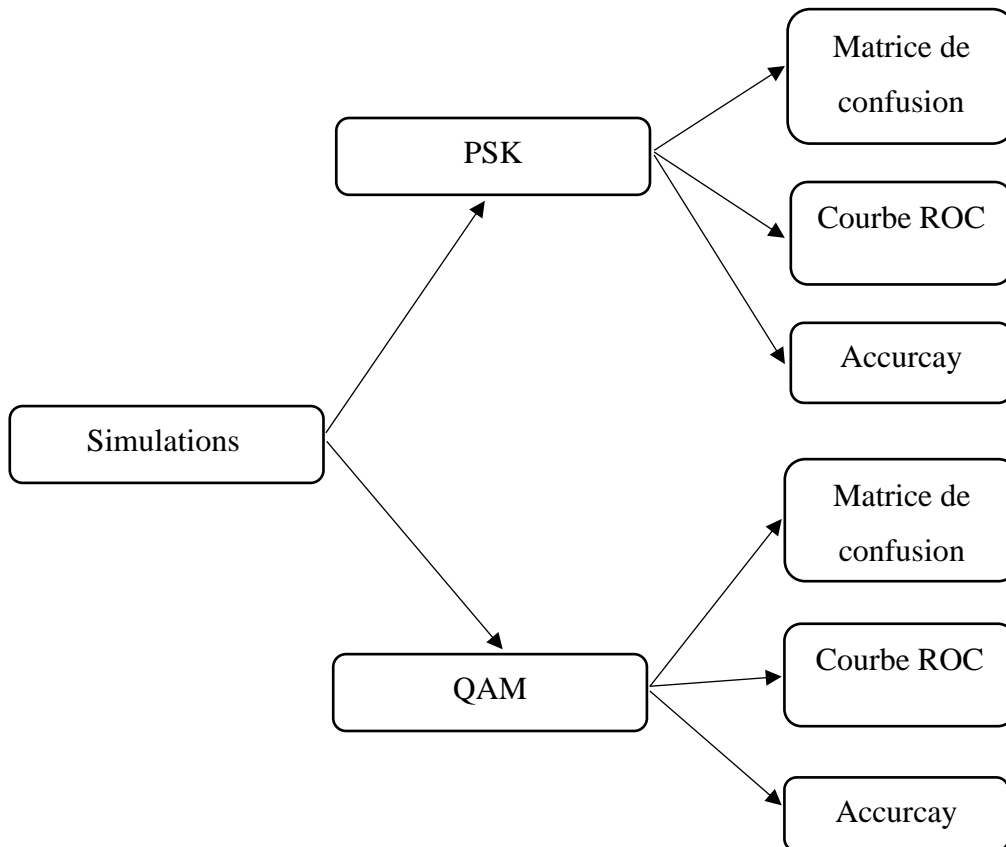


Figure IV.13 : Paramètres d'évaluation.

Évaluation du taux de classification correcte

Après avoir entraîné et classifié les différents types de modulations en utilisant des réseaux de neurones convolutifs constitué de 6 couches de convolutions, nous sommes arrivées à extraire le taux de classification correcte (Accuracy) en fonction de différentes valeurs de rapport signal sur bruit de (-15, 0, 15, 30 dB).

- *Simulations avec un rapport SNR = -15 dB*




Figure IV.14 : Taux de classification pour SNR=-15 dB.

D'après les résultats illustrés sur la figure ci-dessus, deux tracés se présentent dont le premier tracé, la courbe en bleu représente le taux de bonne classification tandis que la ligne discontinue représente la validation de l'entraînement, concernant la deuxième courbe en rouge illustre les erreurs commises par le modèle lors de classification. Après avoir effectué 12 époques d'itérations nous remarquons que pour un SNR = -15dB le classifieur CNN donne des résultats avec un taux de classification qui est de 56.42% qui représente le point final du tracé avec des erreurs commises.

- Simulations avec un SNR = 0dB




Figure IV.15 : Taux de classification avec SNR=0 dB

Pour un SNR = 0dB, les résultats de classification effectués par le modèle est d'une valeur de taux de bonne classification qui est de 56.22%.

- Simulations avec un SNR = 15 dB

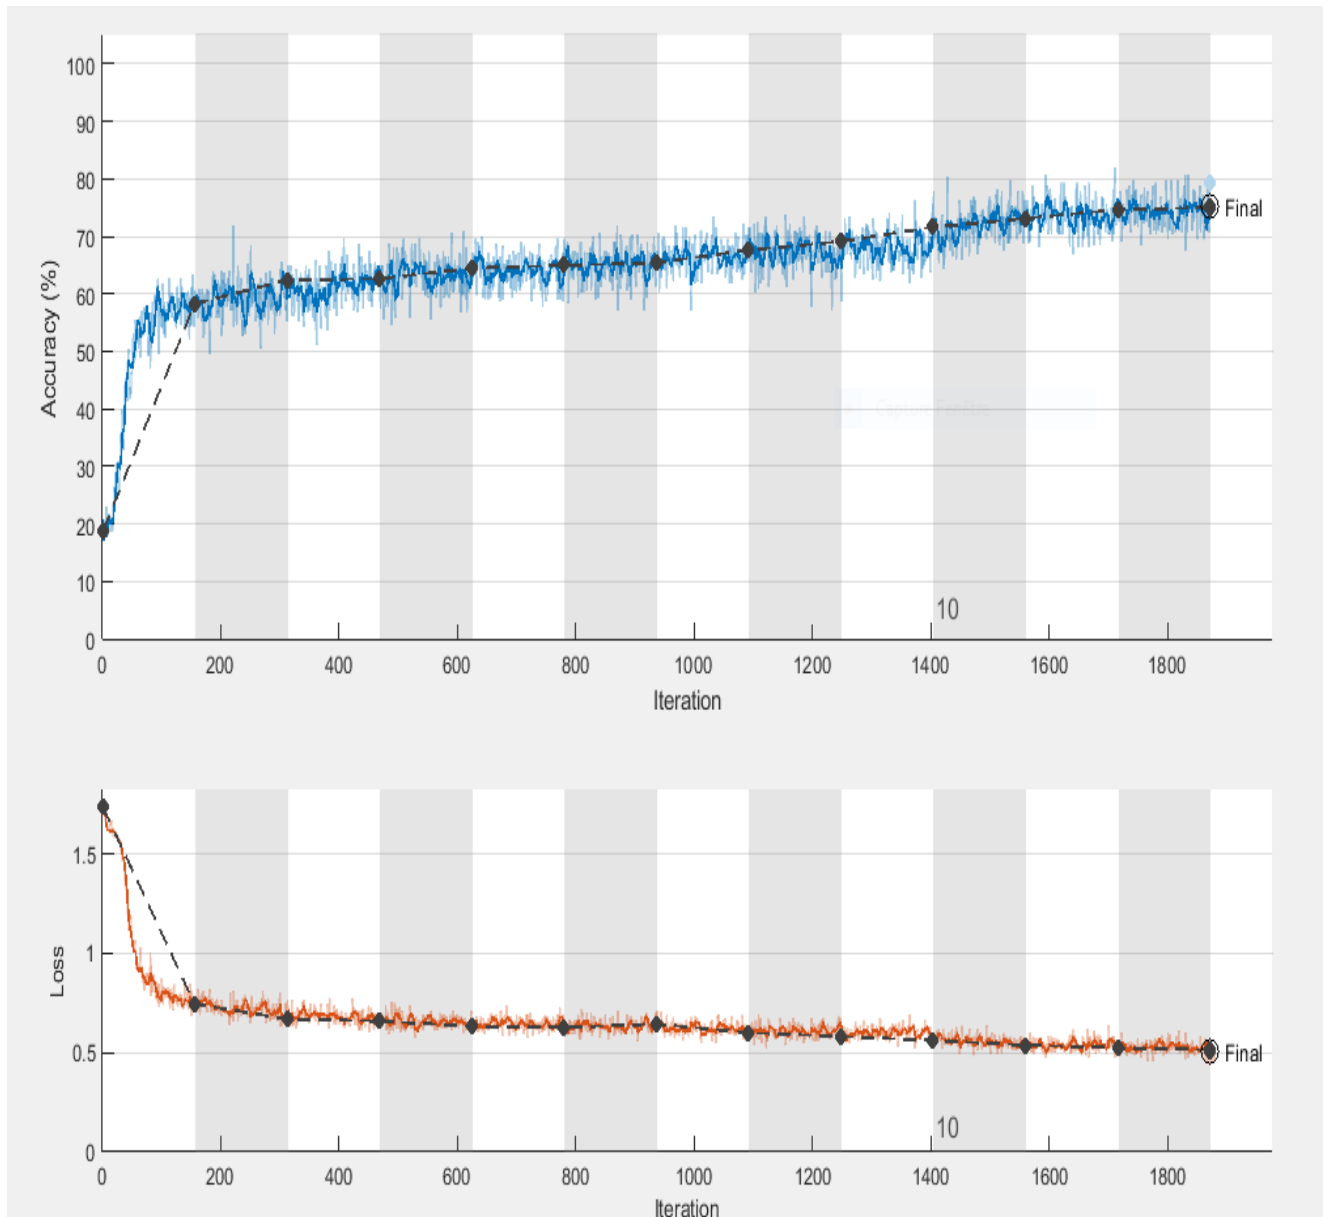


Figure IV.16 : Taux de classification pour SNR=15 dB.

Pour un SNR = 15dB, les résultats de classification sont augmentés jusqu'à atteindre une probabilité de classification de 75.32%, contrairement aux erreurs de classification qui sont diminués.

- Simulations avec un SNR = 30 dB




Figure IV.17 : Taux de classification pour SNR=30 dB.

D'après les résultats illustrés sur la figure ci-dessus, nous remarquons que le classifieur CNN pour SNR=30dB donne les meilleurs résultats par rapport aux autres avec un taux de classification de 92.2% et un minimum d'erreurs.

Dans ces présents résultats nous avons analysé et évalué les performances de notre classifieur selon la probabilité de classification correcte (Accuracy). Nous constatons que ce modèle offre des performances très satisfaisantes pour des valeurs adaptées de rapport SNR. En revanche pour des valeurs à faibles SNR, les taux de classification correcte obtenus sont beaucoup moins satisfaisants.

SNR	Valeur d'Accuracy
-15	56.42%
0	56.22%
15	75.32%
30	92.2%

Tableau IV.2 : Récapitulatif des différentes simulations

Évaluation des matrices de confusion

Afin de caractériser et d'évaluer précisément les performances du système, il est judicieux de renforcer notre jugement décrit précédemment par d'autres métriques issues de la matrice de confusion. Dans ce qui suit, nous donnons les matrices de confusions du classifieur obtenues en variant le rapport SNR= [-15, 0, 20, 30]. Les résultats obtenus sont synthétisés dans les tableaux suivants.

- Simulations avec un SNR = -15 dB

		Classes réelles				
		64QAM	16QAM	8PSK	QPSK	BPSK
Classes prédites	64QAM	542(54.2%)	112(11.2%)	112(11.2%)	115(11.5%)	119(11.9%)
	16QAM	122(12.2%)	508(50.8%)	138(13.8%)	120(12%)	112(11.2%)
	8PSK	130(13%)	110(11%)	598(59.8%)	80(8%)	82(8.2%)
	QPSK	97(9.7%)	102(10.2%)	83(8.3%)	587(58.7%)	131(13.1%)
	BPSK	110(11%)	82(8.2%)	95(9.5%)	127(12.7%)	586(58.6%)

Tableau IV.3 : Matrice de confusion pour SNR=-15 dB.

- Simulations avec un SNR = 0 dB

		Classes réelles				
		64QAM	16QAM	8PSK	QPSK	BPSK
Classes prédites	64QAM	503(50.3%)	96(9.6%)	119(11.9%)	141(14.1%)	141(14.1%)
	16QAM	93(9.3%)	556(55.6%)	129(12.9%)	116(11.6%)	106(10.6%)
	8PSK	114(11.4%)	120(12%)	588(58.8%)	77(7.7%)	101(10.1%)
	QPSK	127(12.7%)	103(10.3%)	71(7.1%)	598(59.8%)	101(10.1%)
	BPSK	119(11.9%)	96(9.6)	99(9.9%)	118(11.8%)	566(56.6%)

Tableau IV.4 : Matrice de confusion pour SNR=0 dB.

- Simulations avec un SNR = 5 dB

		Classes réelles				
		64QAM	16QAM	8PSK	QPSK	BPSK
Classes prédites	64QAM	788(78.8%)	200(20%)	7(0.7%)	4(0.4%)	1(0.1%)
	16QAM	239(23.9%)	721(72.1%)	20(2%)	19(1.9%)	1(0.1%)
	8PSK	9(0.9%)	31(3.1%)	676(67.6%)	282(28.2%)	2(0.2%)
	QPSK	4(0.4%)	28(2.8%)	377(37.7%)	588(58.8%)	3(0.3%)
	BPSK	2(0.2%)	2(0.2%)	2(0.2%)	2(0.2%)	992(99.2%)

Tableau IV.5 : Matrice de confusion pour SNR=15 dB.

- Simulations avec un SNR = 30 dB

		Classes réelles				
		64QAM	16QAM	8PSK	QPSK	BPSK
Classes prédites	64QAM	901(90.1%)	99(9.9%)	0(0%)	0(0%)	0(0%)
	16QAM	131(13.1%)	869(86.9%)	0(0%)	0(0%)	0(0%)
	8PSK	1(0.1%)	3(0.3%)	916(91.6%)	80(8%)	0(0%)
	QPSK	1(0.1%)	2(0.2%)	71(7.1%)	926(92.6%)	0(0%)
	BPSK	0(0%)	0(0%)	0(0%)	2(0.2%)	998(99.8%)

Tableau IV.6 : Matrice de confusion pour SNR=30 dB.

Durant les simulations nous avons généré 10000 trames par chaque type de modulations dans les quelles 80% (8000 trames) pour l'entraînement, 10% (1000 trames) pour la validation et 10% (1000 trames) pour le test.

En augmentant la valeur du SNR, les performances de notre modèle augmentent permettant évoluer de manière à bien classé les types de modulations utilisées. Il ressort également des résultats de la classification que les modulations *BPSK* et *QPSK* sont relativement faciles à classifier par rapport aux modulations d'ordre supérieures *8-PSK*, *16-QAM* et *64-QAM* où le classifieur CNN commettent plus d'erreurs.

Évaluation de la courbe ROC

Un autre indicateur d'évaluation permettant de mesurer la capacité d'un classifieur est appelé l'aire sous la courbe (AUC).

- Simulations avec un SNR = -15 dB

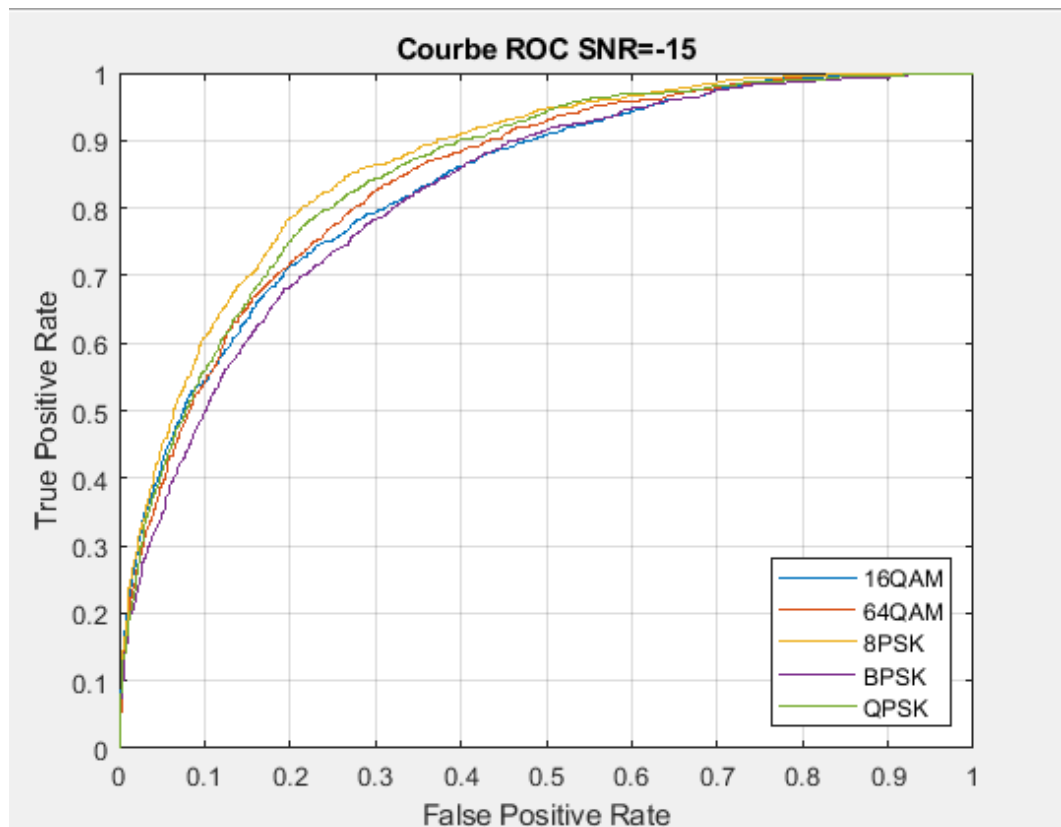


Figure IV.18 : La courbe ROC pour SNR=-15dB.

- Simulations avec un SNR = 0 dB




Figure IV.19 : La courbe ROC pour SNR=0dB.

- Simulations avec un SNR =15 dB




Figure IV.20 : La courbe ROC pour SNR=30dB.


- Simulations avec un SNR = 30 dB

Figure IV.21 : La courbe ROC pour SNR=30dB.

D'après les résultats représentés par la courbe ROC, nous remarquons que les valeurs obtenues sont d'un AUC entre 0.5 et 1 ce qui reflète le haut niveau de classification des réseaux de neurones convolutifs. Nous déduisons qu'avec des SNR faibles le taux de classification est moins précis par rapport aux valeurs obtenues par des SNR adéquats qui tendent vers la performance.

IV.6.Conclusion

Au cours de ce chapitre nous avons étudié les métriques d'évaluations de notre classifieur CNN. Cette étude nous a permises de tester la robustesse et la performance de ce dernier à travers plusieurs simulations avec différentes valeurs SNR pour une meilleure reconnaissance de types de modulations.

Les résultats des simulations ont révélé qu'avec des valeurs de SNR faibles, le taux de bonne classification est autour des 56%, en augmentant le rapport signal sur bruit, les probabilités de classification s'améliorent au fur et à mesure, confirmant ainsi que le CNN dispose d'une grande précision et atteint des performances élevées.

Conclusion générale

La classification de modulations est une tâche importante dans le domaine des télécommunications. Bien que les capacités des activités réalisées dans ce secteur soient nombreuses, aucune méthode n'est jugée fiable à 100%, mais au fur et à mesure, les nouveaux travaux essaient d'améliorer les scores pour des meilleurs résultats.

C'est dans ce cadre que s'inscrit notre travail, qui a pour objectif de proposer une méthode qui réalise une classification performante.

Pour réaliser notre travail de classification nous avons utilisé le Deep Learning, la méthode d'apprentissage qui a montré ses performances ces dernières années et nous avons choisi un modèle de réseau CNN à six couches comme classifieur. Les résultats de simulation obtenus lors de la phase de test confirment l'efficacité de notre approche. Le classifieur obtenu assure de très bonnes performances de classification.

Nos différentes investigations nous ont permises d'approfondir nos connaissances dans notre spécialité notamment dans les domaines de radio cognitive, de Deep Learning et de classification automatique de modulation à base de réseaux CNN. Nous espérons que notre travail puisse servir pour de futures études.

Bibliographies

- [1] Z. A. Mahmood A.Abdulsattar, «"Energy Detection for spectrum sensing in cognitive radio: survey",» in *International Journal of Computer Networks & Communications (IJCNC)*, vol. 4, 2012.
- [2] J.Mitola, «"Cognitive radio: An integrated agent architecture for software defined radio",» *Ph.D. Thèse, Institut royal de technologie (KTH)*, 2000.
- [3] A. A. B. Benmammar, «"Application de l'intelligence artificielle dans les réseaux de radio cognitive",» *Gestion et contrôle intelligents des réseaux : Sécurité intelligente, optimisation multicritères, Cloud Computing, Internet of Vehicles, radio intelligente*, p. 233, 2020.
- [4] A. Metref, «"Contribution à l'étude du problème de synchronisation de porteuse dans le contexte de la Radio Intelligente ".Institut d'Electronique et des Télécommunications de RENNES 1,» 2010.
- [5] B.Benmammar, «"Allocation de ressources dans un réseau de radio cognitive en utilisant JADE". Laboratoire de Télécommunication Tlemcen, UABT, Algérie.,» 2015.
- [6] N. u. H. S. L. H.-S. K. i. Waled. Ejaz, «"IS : Intelligent spectrum sensing scheme for cognitive radio networks, Eurasip Journal on Wireless Communications and networking",» 2013.
- [7] J.Mitola, "Cognitive Radio Architecture: The Engineering Foundations of Radio XML", Wiley, Éd., 2006.
- [8] I. L. Badr Benmammar, «"Négociation de spectre dans les réseaux de radio cognitive".Laboratoire de Télécommunication de Tlemcen.,» 2014.
- [9] K. k. Ibrahim Develi, «"Spectrum sensing in cognitive radio networks: threshold optimization and analysis",» *EURASIP Journal on Wireless Communications and Networking*, 2020.

- [10] A. K. Zhechen Zhu, Automatic Modulation Classification Principles, Algorithms and Applications, Wiley, Éd., Londre, 2015.
- [11] P. D. Jérôme Callut, "Séparateurs à Vaste Marge Optimisant la Fonction F", Nice, 2005.
- [12] M. S. Nick Guenther, «Support vector machines,» n° % 14, p. 917–937, 2016.
- [13] O. Campesato, Artificial Intelligence Machine Learning and Deep Learning, D. Pallai, Éd., New Delhi, 2020.
- [14] M. S. John G.Proakis, "Digital communications".New York:McGraw-hill, 2001.
- [15] T. S.Rappaport, "Wireless Communication Principales and Practice".Prentice Hall PTR, 2002.
- [16] B. N. E. I. Tlidjani Zakaria Daeia Eddine, "Etude et simulation des modèles des canaux à évanouissement du systèmes LTE", 2016-2017.
- [17] L. W. Y. L. YIhuai Yang, "Propagation Channel Modeling for Rayleigh and Rice Fading".School of Automatic Control and Mechanical Engineering, Kunming University, 650214, China, 2014.
- [18] H. Abdi, «"Les Réseaux de neurones",» Apress universitaires de Grenoble, 1994.
- [19] S. G. Andrea C.Müller, «"Introduction to machine learning with Python: a guide for data scientists". O'Reilly Media, Inc,» 2016.
- [20] Y. Z. W. P. J. C. L. P. Q. Liang Huang, «"Visualizing Deep Learning-based Radio Modulation",» 2021.
- [21] G. Dreyfur, " Réseaux de neurones : Méthodologie et application ", Eyrolles, 2004.
- [22] C. Touzet, "LES RESEAUX DE NEURONES ARTIFICIELS INTRODUCTION AUX CONNEXIONNISME", 2016.
- [23] M. Parizeau, " Réseaux de Neurones (Le perceptron multicouche et son algorithme de retropropagation des erreurs). s.l. : Université Laval", 2004.
- [24] J. M. K. M. A.K. Jain, "Artificial Neural Networks :Tutorial", Mars 1996.

- [25] A. Assoum, "Etude de la tolérance aux aléas logiques des réseaux de neurones artificiels". Thèse doctorat, 1997.
- [26] G. Gelly, «"Les réseaux de neurones récurrents pour le traitement automatique de la parole. Réseau de neurones".Université Paris Saclay,» 2017.
- [27] Y.Bourek, "Etude de la décharge électrique par l'intelligence artificielle", thèse de doctorat, Université de Batna2, 2016.
- [28] S. J. D. Y. X. L. A. E. G. Y. C. E. Sharan Ramjee, "Fast Deep Learning for Automatic Modulation Classification", 16 janvier 2019.
- [29] A. F. M. Agarap, "An Architecture Combining Convolutional Neural Network (CNN) and Support Vector Machine (SVM) for Image Classification", 7 février 2019.
- [30] I. S. G. E. H. A. Krizhevsky, «"ImageNet Classification with Deep Convolutional Neural Networks",» vol. 60, n° %16, 2017.
- [31] B. Graham, «"Fractional Max-Pooling".University of Warwick,» 13 may 2015.
- [32] S. Z. Z. L. S. L. X. G. S. Z. L. Xiaobo Wang, «"Ensemble Soft-Margin Softmax Loss for Image Classification",» 2018.
- [33] A. B. & F. Recher, "DEEPMATH Mathématiques des réseaux de neurones", janvier 2001.
- [34] H. TAYAKOUT, "Détection itérative par Turbo codage combinant différentes techniques à base de systèmes MIMO". Thèse de doctorat en Electronique, Ecole Nationale Polytechnique, 2019.
- [35] T. O. a. J. Hoydis, «"An introduction to deep learning for the physical layer". IEEE Trans. Cognit. Commun. Netw,» vol. 3, n° %14, p. 563575, 2017.
- [36] P. P. H. H. Chaoyun Zhang, «"Deep Learning in Mobile and Wireless Networking: A Survey",» 2019.

Abstract

The work presented in this dissertation concerns the cooperative diversity with which we used the smart radio features that allow cognitive radio users to listen to the spectrum and to detect the existing white spaces in the automatic recognition of the modulation type and this with the aim of improving the performance and the quality of the transmissions.

This project concerns the study of the performances of an automatic classification system of modulation type using a recent technology known as deep learning with the help of using convolutional neural networks as a solution related to the processing of complex data. The simulation results obtained have shown better performance of the proposed solutions and of the proposed solutions and a high classification accuracy of different types of modulations.

Keywords :

Cooperative diversity, cognitive radio, automatic classification system of modulation type, deep learning, convolutional neural networks.

Résumé

Le travail présenté dans le cadre de ce mémoire concerne la diversité coopérative avec laquelle nous avons utilisées les fonctions de radio intelligente qui permet aux utilisateurs de la radio cognitive d'écouter le spectre et de y détecter les espaces blancs existants dans la reconnaissance automatique du type de modulation et ce dans le but d'améliorer d'avantage les performances et la qualité des transmissions.

Ce projet porte sur l'étude des performances d'un système de classification automatique de type de modulation en utilisant une technologie récente connue sous l'appellation de l'apprentissage en profondeur à l'aide des réseaux de neurones convolutifs comme solution liée au traitement des données complexes. Les résultats de simulations obtenus ont démontré de meilleures performances des solutions proposées et une grande précision de classification de différents types de modulations.

Mot Clés :

Diversité coopérative, radio intelligente, radio Cognitive, La reconnaissance automatique de type de modulation, apprentissage en profondeur, réseau de neurones convolutifs.