

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieure et de la Recherche Scientifique



Université Abderrahmane Mira
Faculté de Technologie



Département d'Automatique, Télécommunication et d'Electronique

Projet de Fin d'étude

Pour l'obtention du diplôme de Master

Filière : *Télécommunications*

Spécialité : *Réseaux & télécommunications*

Thème

*Reconnaissance automatique de types de modulation
à base de réseau de neurones*

Préparé par :

Mr Lyes ABDELLI et Mr Rafik KEBICHE

Dirigé par :

Mr. M. TOUNSI

Examiné par :

Mr. A. MEKHMOUKH

Mme M. OUALI

Année universitaire : 2020/2021

Remerciements

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

Nous adressons nos plus profonds remerciements, toute notre gratitude et notre reconnaissance à notre encadreur : Mr TOUNSI, Enseignant-chercheur à l'université Abderrahmane Mira de Bejaia, pour nous avoir dirigés durant ce travail et nous avoir permis de le réaliser dans les meilleures conditions. Nous tenons particulièrement à le remercier de la liberté d'action qu'il nous a accordée à chaque étape du mémoire. Nous espérons avoir été dignes de la confiance qu'il nous a accordée et que ce travail est finalement à la hauteur de son espérance. Merci encore pour vos encouragements continuels sans lesquels nous n'aurions jamais réussi à aller jusqu'au bout. Ce fut un plaisir et un grand honneur de travailler sous votre direction.

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

Nous n'oublions pas aussi de remercier chaleureusement et à adresser nos plus vives et cordiales sympathies à tous ceux qui, de près ou de loin, ont apporté leur contribution, aussi modeste soit-elle, à la réalisation de ce travail à travers lequel nous espérons avoir apporté une pierre au grand édifice de la recherche dans le vaste domaine des télécommunications.

Dédicaces

Je dédie ce modeste travail à :

A Ma chère mère qui m'a soutenu durant toutes mes études, qui a fait de moi ce que je suis aujourd'hui je lui saurai éternellement reconnaissant.

A ma chère grand-mère : FiFi

A mes cousins et cousines : Samira, Walid, Fayçal, Salim, Riad

A ma tante et mon oncle : Fatiha et Omar

Au professeur : K. Moussaceb

A mon binôme Lyes et toute sa famille

A mes chers amis de la promo télécom : Dalil, Samy, Maria, Farah, Rosa, Lydia et Leila.

Sans oublier : Hssicen, Akssel, Walid, Samy, Reda, Houcine, Reda

A tous mes ami(e)s de la promotion de Télécommunication Promo 2020/2021

« RAFIK »

Dédicaces

Je dédie ce modeste travail à :

Mes très chers parents qui m'ont soutenu durant toutes mes études, qui ont fait de moi ce que je suis aujourd'hui je leurs saurais éternellement reconnaissant.

A mon frère et ma sœur : Lamine, Souad

A mes chers amis de la promo télécom : Aissa, Dalil, Farah, Maria, Leila, Yasmina, Rosa, Lydia, Lynda, Sihem, Yasmine, Jugurta

Sans oublier Ghani, Fahem, et Yazid

A mon binôme RAFIK et toute sa famille

A tous mes ami(e)s de la promotion de Télécommunication Promo 2020/2021

« LYES »

Table des matières

Liste des abréviations.....	i
Introduction générale.....	1

CHAPITRE I : Introduction à la Radio Cognitive

I.1 Introduction.....	4
I.2 Radio logicielle	4
I.2.1 Radio logicielle restreinte	4
I.2.2 Relation entre RC et SDR.....	5
I.3 Définition de la radio cognitive	5
I.3.1 Architecture de la radio cognitive.....	6
I.3.2 Les fonctions de la radio cognitive	7
I.4 Techniques de détection de spectre.....	8
I.4.1 La détection de spectre en utilisant l'AMR	8
I.5 Statistiques d'ordre supérieur	10
I.6 Classification.....	11
I.6.1 Séparateurs vaste marge SVM	12
I.6.2 Réseaux neurones artificiels ANN.....	12
I.6.3 K plus proches voisins (KNN).....	13
I.7 Conclusion	14

CHAPITRE II : Systèmes SM-MIMO

II.1 Introduction	16
II.2 Systèmes MIMO.....	16
II.2.1 Notion et principe de diversité.....	17
II.2.2 Configurations MIMO.....	18

II.2.3 Algorithmes de réception associés aux systèmes MIMO	19
II.3 Modulation spatiale	20
II.3.1 Principe de la modulation SM	21
II.3.2 Association SM-OFDM.....	22
II.4 Conclusion	24

CHAPITRE III : Introduction aux Réseaux de Neurones Artificiels

III.1 Introduction	26
III.2 Historique des RNA	26
III.3 Modèle Biologique des neurones	27
III.4 Modèle formel des neurones	27
III.4.1 Les types d'apprentissage des réseaux de neurones.....	28
III.4.2 Règles d'apprentissage.....	29
III.4.3 Architecture des réseaux neurones	30
III.4.4 Fonction d'activation.....	33
III.5 Algorithme de rétropropagation	35
III.5.1 Algorithme d'apprentissage d'un réseau monocouche (sans couche cachée).....	35
III.5.2 Algorithme d'apprentissage d'un réseau multicouches (MLP).....	36
III.6 Applications des ANN	36
III.7 Avantages et inconvénients	37
III.8 Conclusion.....	37

CHAPITRE IV : Performances SM-MIMO & Classification AMC

IV.1 Introduction.....	39
IV.2 Évaluation des performances de systèmes SM-MIMO.....	39
IV.2.1 Métriques de performances utilisées.....	39
IV.2.2 Paramètres de simulation	40

IV.2.3 Performances obtenues avec la modulation M-QAM.....	40
IV.2.4 Performances obtenues avec la modulation M-PSK.....	44
IV.3 Évaluation des performances des classifieurs.....	46
IV.3.1 Métriques des performances utilisées	46
IV.3.2 Méthodologie de simulation.....	47
IV.3.3 Réseau de neurones utilisé	49
IV.3.4 Évaluation du taux de classification correcte.....	49
IV.3.5 Évaluation des matrices de confusion	50
IV.3.6 Détermination des courbe ROC	54
IV.4 Conclusion	58
Conclusion générale	60
Références Bibliographiques	62

Liste des abréviations

AMR	Reconnaissance automatique de type de modulation
ANN	Artificial Neural Network
AOS	Accès Opportuniste au Spectre
ART	Adaptive Resonance Theory
AUC	Area Under the Curve (aire sous la courbe)
BER	Bit Error Rate
BPSK	Binary Phase-Shift Keying
CFD	Détection des caractéristiques cyclstationnaires
CNN	Convolutional Neural Network
CP	Cyclic Prefix
ED	Détection d'énergie
EE	Efficacités Energétique
FB	Features Based
FFT	Fast fourier transform
FLN	Functional Link Network
HOC	Higher-Order Cumulants
HOM	Higher-Order Moments
HOS	Higher order statistic
KNN	K-Nearest Neighbours
MFD	Détection par filtrage adapté
MIMO	Multiple –Input Multiple-Output
MISO	Multiple-Input Single-Output
ML	Maximum de vraisemblance
MLP	Perceptron multicouche
MMSE	Minimum Mean Square Error
MSE	Mean Square Error
MV	Maximum de Vraisemblance
OFDM	Orthogonal frequency-division multiplexing

PAM	Pulse Amplitude Modulation
PMC	Perceptron MultiCouche
PNN	Probabilistic neural network
PSK	Phase-Shift Keying
PU	Primary User
QAM	Quadrature Amplitude Modulation
QPSK	Quadrature Phase-Shift Keying
QoS	Quality of service
RBF	Radial Basis Function
RC	Radio Cognitive
RF	Radio Fréquence
RI	Radio Intelligente
RN	Réseaux de neurones
RNA	Réseaux de neurones artificiels
ROC	Receiver Operating Characteristic
RSB	Rapport Signal sur Bruit
SDR	Software-Defined Radio
SVM	Support Vector Machines (Séparateurs à vaste marge)
SE	Spectral efficiency
S/B	Rapport Signal sur Bruit
SISO	Single-Input Single-Output
SIMO	Single- Input Multiple-Output
SNR	Signal to Noise Ratio
SM	Spatial Modulation
SM-MIMO	Spatial Modulation- Multiple –Input Multiple-Output
SR	Software radio
SU	Secondary User
V-BLAST	Vertical – Bell – Laboratories –Layered –Space – Time
ZF	Zero Forcing

Introduction générale

Le domaine des télécommunications est en constante évolution, il tend à prendre une place de plus en plus importante dans les sociétés actuelles. En effet, les technologies se succèdent et offrent des débits de plus en plus élevés. Ceci dit, ces développements n'ont été possibles qu'après divers efforts de recherche de solutions innovantes pour parer à différentes contraintes telles que la pénurie de spectre relativement à la multiplicité des normes de communication sans fil. Il convient de noter dans ce contexte, que l'utilisation du spectre de fréquence n'est pas uniforme [1] ; et l'idée a donc naturellement tourné vers le développement d'outils permettant de mieux utiliser le spectre.

C'est ainsi qu'a émergé la radio cognitive (RC) : une nouvelle technologie visant à implémenter des fonctions de cognition dans les émetteurs et récepteurs, leur permettant de s'adapter et tirer profit de l'évolution de leurs environnements radio de façon dynamique et autonome. La fonction de partage de spectre en était l'un des premiers objectifs.

Nous nous intéressons dans notre présent mémoire, à une autre fonction importante de la RC : la reconnaissance automatique de modulation (AMR), très utilisée dans diverses applications où la surveillance des communications est stratégique, puisqu'elle permet d'extraire des caractéristiques représentatives du type de signaux inconnus reçus.

Nous étudions cette application dans des systèmes de communication sans fil SM-MIMO associant la modulation spatiale (SM) [2] à la technologie Multiple-Input-Multiple-Output (MIMO). Cette dernière a été développée afin d'améliorer les débits de transmission et la qualité du rapport signal sur bruit (RSB ou SNR) en exploitant des réseaux d'antennes à l'émission et/ou à la réception. Quant à la modulation SM, elle vise une meilleure efficacité énergétique avec de nouvelles structures d'antennes plus compactes et reconfigurables sur une seule chaîne de transmission radio (RF) tout en ne conservant une faible complexité.

Le travail, qui nous a été demandé, se divise en deux parties :

- Une première partie sur l'évaluation des performances de diverses configurations antennaires de systèmes SM-MIMO ;
- Une seconde partie portant sur la tâche AMR, scindée elle aussi en deux parties : d'abord, la détection des symboles de constellations numériques MPSK et MQAM, pour l'extraction de caractéristiques pertinentes des types de modulations considérées ; suivie de la classification automatique à base de réseaux de neurones des types de modulation.

Notre travail est synthétisé dans ce présent mémoire et organisé en quatre chapitres :

- Dans le premier chapitre, nous présentons les principes et les fonctionnalités de la radio cognitive. Notre intérêt porte sur la fonctionnalité de reconnaissance automatique de modulation ;
- Le second chapitre est réservé aux techniques MIMO et à la modulation spatiale pour leur association dans des systèmes SM-MIMO ;
- Le troisième chapitre décrit la méthode de classification automatique choisie, à savoir les réseaux de neurones artificiels (ANN) ;
- Dans le dernier chapitre, nous donnons les résultats de nos simulations sous l'environnement Matlab. Nous présentons des évaluations de performances de divers systèmes SM-MIMO, l'architecture du réseau ANN retenu pour l'identification des types de modulations à base d'extraction de statistiques d'ordre supérieur des signaux.

Nous terminons par une conclusion générale à nos investigations avec quelques perspectives possibles pour notre travail, suivie des références bibliographiques utilisées.

CHAPITRE I

Introduction à la Radio Cognitive

I.1 Introduction

L'évolution des technologies sans-fil et l'augmentation exponentielle des abonnés ont été marquées par l'apparition de nouveaux appareils intelligents capables d'offrir des meilleurs débits et des services très variés [3]. Mais cela a engendré une forte demande en termes de ressources spectrales qui devenaient de plus en plus rares. Pour arriver à bout de ce problème, il était primordial de trouver des solutions d'accès dynamique au spectre, c'est alors que la radio cognitive est apparue.

I.2 Radio logicielle

La radio logicielle (SR) est une classe de radio programmable et reconfigurable, son objectif est de dématérialiser complètement l'interface radio[4], c'est-à-dire qu'elle ne sera constitué que d'une antenne et d'un ADC (convertisseur analogique-numérique), et que les propriétés de la fréquence porteuse, de la bande passante du signal, de la modulation et de l'accès au réseau sont définies par logiciel ; ce qui permet l'utilisation de n'importe quel standard de communication, par simple modification du logiciel embarqué. Or le parfait n'existe pas, c'est pourquoi on parlera de radio logicielle restreinte.

I.2.1 Radio logicielle restreinte

La radio logicielle restreinte (SDR) est un système de radiocommunication configurable utilisant des techniques de traitement numérique du signal sur des circuits numériques programmables. Il est considéré comme étant le plus haut niveau d'avancement de la radio logicielle. Ce dernier comporte une partie analogique et une partie numérique.

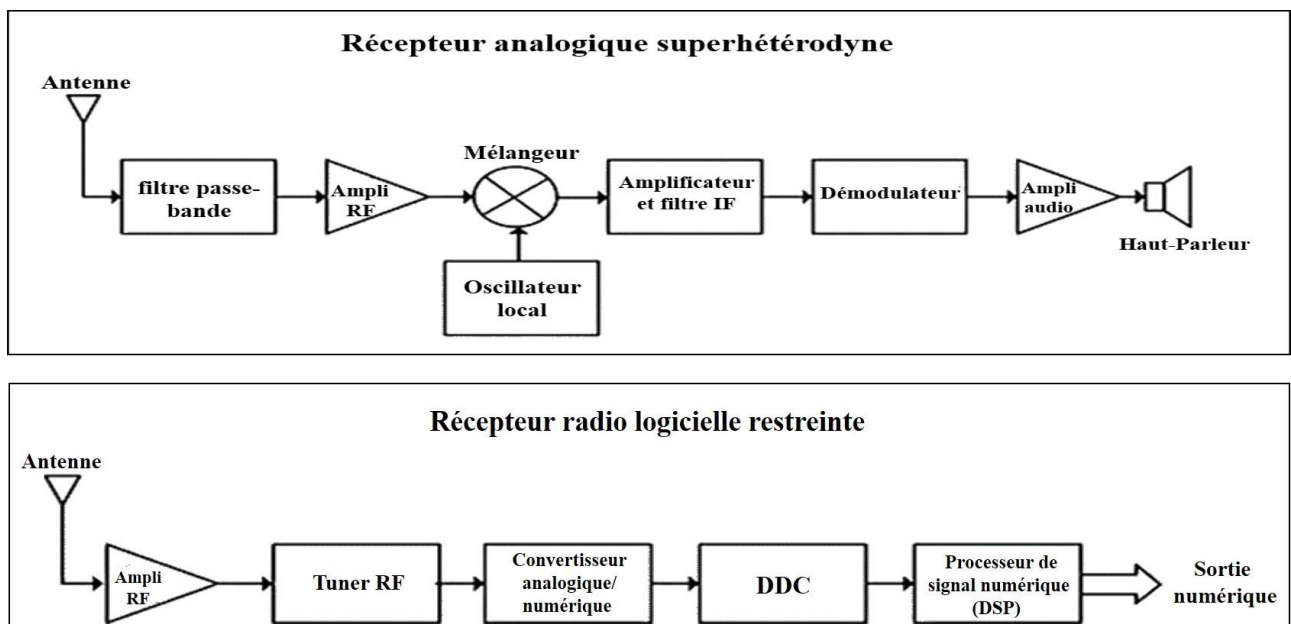


Figure I.1 : Exemple d'un récepteur radio traditionnel et d'un récepteur basé SDR.

Dans la figure I.1, la partie analogique regroupe l'antenne ainsi que le modulateur RF. Le CAN forme le pont entre la partie analogique et la partie numérique de la radio logicielle. Les fonctions du récepteur SDR après le CAN représentent la partie numérique [4], et sont implémentées avec des circuits numériques programmables, permettant des modifications et des mises à jour programmables.

I.2.2 Relation entre RC et SDR

La principale caractéristique de la RC est de faire adapter ses paramètres tels que la fréquence porteuse, le type de modulation, et la largeur de bande, et de les modifier en fonction de plusieurs facteurs : l'environnement radio, les besoins de l'utilisateur, l'état du réseau...La SDR offre plus de flexibilité afin de gérer les fonctionnalités radio et cela en évitant l'utilisation de circuits et composants analogiques [5]. C'est pourquoi la RC est conçue autour de la SDR. En d'autres termes, la SDR est le cœur de la radio cognitive. La figure ci-dessous montre un modèle simplifié qui décrit la relation entre la radio cognitive et la radio logicielle restreinte.

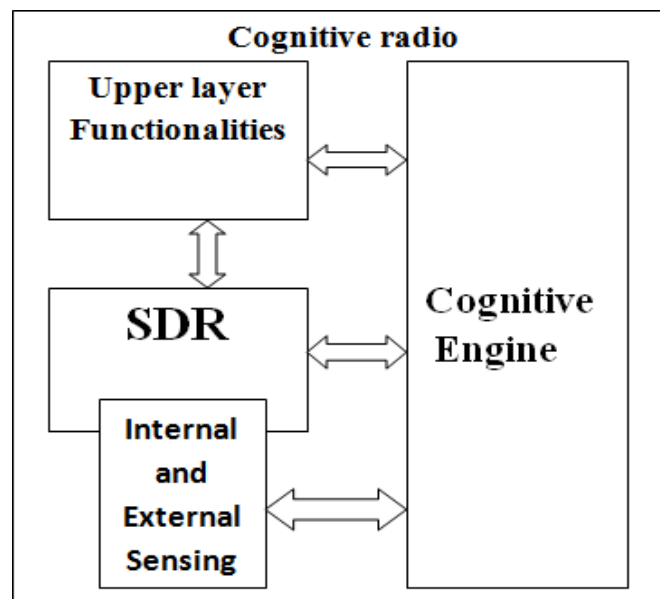


Figure I.2 : Relation entre RC et SDR.

I.3 Définition de la radio cognitive

« Une radio cognitive peut connaître, percevoir et apprendre de son environnement puis agir pour simplifier la vie de l'utilisateur » [6]. Ces quelques mots de Joseph Mitola suffisent largement pour définir une radio intelligente ou une radio cognitive. En d'autres termes, une radio cognitive est une

forme de communication sans fils dans laquelle un équipement émetteur et/ou récepteur est capable d'adapter certains de ses paramètres de façon automatique en fonction de son environnement.

C'est un système de communication sans fil intelligent, qui alloue dynamiquement la ressource spectrale entre les abonnés. Intelligente et intuitive, la RC a la capacité de détecter quand la bande est libre pour l'allouer à un utilisateur.

I.3.1 Architecture de la radio cognitive

La structure de la radio cognitive englobe un ensemble de composants matériels ou logiciels, de fonctions ainsi que des règles de conception qu'on appelle des règles de design. Elle est construite autour de la radio logicielle avec ajout de quelques fonctions ; aptitude cognitive, capacité de raisonnement, intelligence ainsi qu'une modélisation de son environnement [7]. Il existe une multitude de modèles qui représente l'architecture de la radio cognitive. La figure ci-dessous décrit une version simplifiée et minimale de cette dernière.

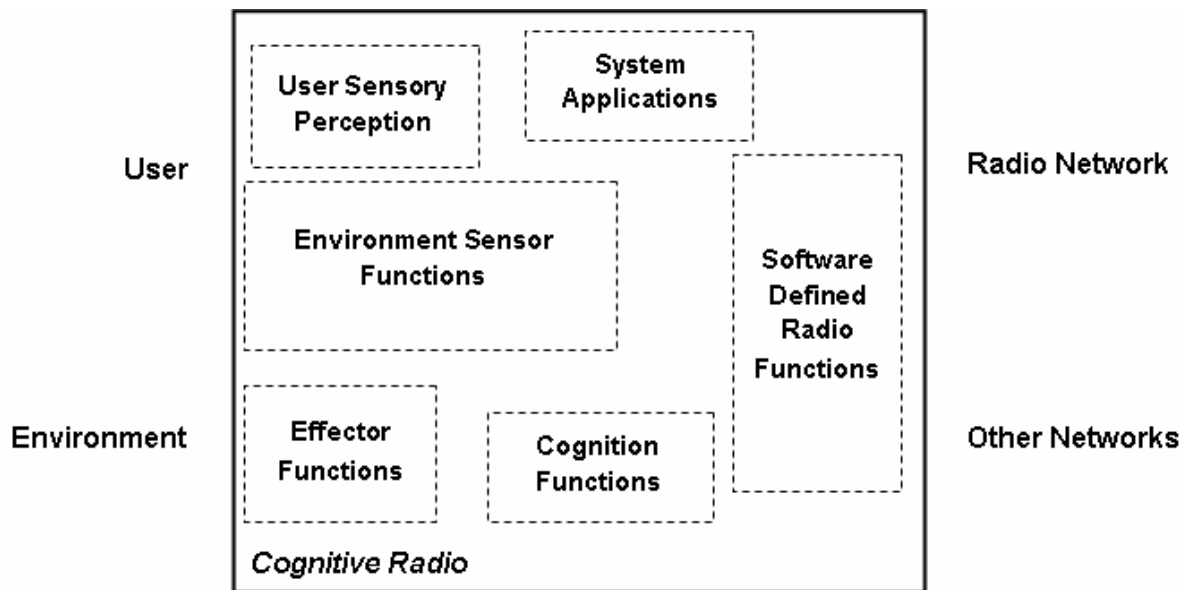


Figure I.3 : Architecture de la radio cognitive.

Elle est constituée de 6 boîtes noires auxquelles on a attribué des fonctions [8] :

- La perception sensorielle de l'utilisateur, inclut l'interface haptique (du toucher), acoustique, la vidéo et les fonctions de détections et de la perception.
- Les capteurs de l'environnement local (emplacement, température, accéléromètre, etc.)
- 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.3.2 Les fonctions de la radio cognitive

Dans un réseau RC, les utilisateurs du spectre de fréquence sont divisés en deux catégories : utilisateurs primaires PU et utilisateurs secondaires SU.

- Un utilisateur primaire (PU) est un usager qui possède une licence sur une bande de fréquence délivrée par l'autorité de régulation du spectre, et donc prioritaire à émettre sur cette bande
- Un utilisateur secondaire (SU) est un utilisateur qui ne dispose pas licence, mais utilise de manière opportune, la bande de l'utilisateur PU sans engendrer d'interférences.

Pour cela, la radio cognitive a plusieurs fonctions principales qui sont [9] :

- **Détection du spectre** : cette fonction consiste à détecter le spectre non utilisé et à le partager sans interférences avec autrui ;
- **Gestion du spectre** : c'est la fonction où, après analyse, un utilisateur SU décide quelle bande de fréquence répond le plus à ses exigences ;
- **Mobilité du spectre** : c'est un processus effectué lorsqu'un utilisateur primaire souhaite récupérer son canal déjà occupé par un utilisateur secondaire ;
- **Décision sur le spectre** : cette dernière doit tenir compte de plusieurs critères comme la QoS exigée par l'application, le besoin en bande passante, et cela afin d'attribuer un canal à un utilisateur.
- **Partage du spectre** : c'est un ensemble de protocoles servant à éviter les interférences entre usagers qui utilisent la même bande fréquentielle.

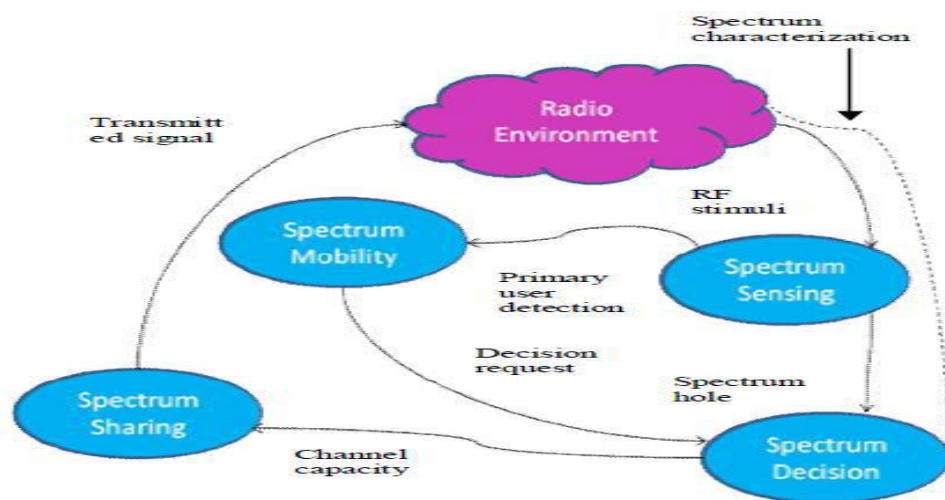


Figure I.4 : Fonctions de la radio cognitive.

I.4 Techniques de détection de spectre

La détection de spectre est l'étape la plus cruciale dans un réseau RC. Elle consiste à détecter de manière fiable et rapide si, un utilisateur PU est absent ou non sur un canal, afin qu'un utilisateur secondaire puisse se caler sur ce dernier sans interférences.

Cela consiste à ce qu'un SU balaye une large gamme de fréquences afin de trouver les espaces blancs disponibles sur le spectre [10]. Ce processus peut être décrit comme étant un problème de détection binaire, composé de deux hypothèses :

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

Où : H_0 désigne l'hypothèse d'absence du PU sur le canal de fréquence ;

H_1 indique l'hypothèse de présence du PU sur le canal ;

$r(t)$, $s(t)$, $n(t)$ et h sont respectivement le signal reçu, le signal transmis, le bruit de fond additif et le gain du canal.

Diverses techniques de détection du spectre en été proposées, parmi lesquelles on peut citer [11] :

- La détection d'Énergie (Energy Detection) ;
- La détection par filtrage adapté (Matched-filter Detection) ;
- La détection des caractéristiques cyclostationnaires (Cyclostationary Feature Detection).

Cependant ces méthodes présentent divers inconvénients (voir tableau 1.1) qui sont considérés comme des inconvénients et limitent leurs applications pratiques dans les environnements radio cognitifs.

Afin de venir à bout de ces problèmes, la détection automatique de type de modulation a été présentée comme une nouvelle technique permettant d'améliorer les performances des réseaux cognitifs.

I.4.1 La détection de spectre en utilisant l'AMR

La reconnaissance automatique de modulation ou AMR est une technique qui permet aux dispositifs radio cognitifs de détecter la présence d'un PU sur le spectre pour surmonter les inconvénients des méthodes classiques. Son principe est que tous les utilisateurs primaires utilisent un type de modulation pour la transmission [12]. Et donc, il est largement suffisant, en connaissant le type de modulation utilisé, de s'informer sur l'état du PU dans le canal de fréquence. Un grand nombre de méthodes de classification de type de modulation ont été développées. Elles ont été divisées en deux catégories, celles basées sur une approche de décision théorique et celles basées sur une reconnaissance de tendance statistique.

<i>Techniques</i>	<i>Avantages</i>	<i>Inconvénients</i>
<i>Détection d'énergie (ED)</i>	<ul style="list-style-type: none"> - Ne nécessite aucune information a priori sur les signaux des PUs. - Utilisé pour détecter des signaux à large bande. 	<ul style="list-style-type: none"> - Mauvaise performance dans les environnements bruités
<i>Détection par filtrage adapté (MFD)</i>	<ul style="list-style-type: none"> - Optimise le SNR du signal - Temps de détection court 	<ul style="list-style-type: none"> - Nécessite des informations a priori sur les signaux des PUs (type de modulation, forme des impulsions)
<i>Détection des caractéristiques cyclostationnaires (CFD)</i>	<ul style="list-style-type: none"> - Sépare entre signal utile et bruit - Utilisée dans des environnements à faible SNR. - Précision dans l'estimation de la fréquence porteuse 	<ul style="list-style-type: none"> - Complexité de calcul - Nécessite des informations a priori sur les signaux des PUs.

Tableau I.1 : Avantages et inconvénients des techniques de détection de spectre classiques.

I.4.1.1 Méthodes basées sur l'approche de décision théorique

Le principe de ces méthodes repose sur l'utilisation de paramètres relevant d'hypothèses ou d'un modèle de probabilité. Des critères de vraisemblance maximale (ML) et de probabilité à postériori maximale (MAP) sont utilisés pour choisir parmi une liste de modulations candidates. Une description statistique des signaux modulés et du canal de transmission y est nécessaire.

I.4.1.2 Méthodes basées sur une reconnaissance de tendance statistique

Les méthodes basées sur une reconnaissance de tendance statistique sont construites en deux étapes, une étape d'extraction de caractéristiques pertinentes caractérisant les signaux reçus, et une étape de classification afin de prendre une décision à propos du type de modulation utilisé [13].

Les caractéristiques les plus utilisées sont :

- Caractéristiques spectrales.
- La transformée en ondelettes.
- Caractéristiques cyclo-stationnaires.
- Les statistiques d'ordre supérieur.

Le processus comprend trois étapes, prétraitement du signal pour minimiser le bruit, extraction de caractéristiques et enfin la reconnaissance du type de modulation. La figure (I.5) décrit ce processus.




Figure I.5 : Processus AMR à base de FB.

I.5 Statistiques d'ordre supérieur

Les Statistiques d'Ordre Supérieur à 2 (HOS), ou les moments et cumulants d'ordre supérieur à 2 donnent une description plus complète des données et de leurs propriétés. Le moment d'un signal est égal à l'espérance du signal élevé à une puissance déterminée par l'ordre du moment. Le moment du premier ordre est la moyenne d'un signal, tandis que le moment du deuxième ordre indique généralement la puissance du signal.

Pour un processus aléatoire stationnaire à valeurs complexes, y , les moments d'ordre supérieur (HOM) sont définis comme suit [14] :

$$E_{x,a,b} = E[x^a(\bar{x})^b] \quad a, b \in \mathbb{Z} \quad (\text{I.2})$$

Où E désigne l'espérance, x la variable et \bar{x} son conjugué.

L'ordre de ce moment est égal à $(a + b)$

Les cumulants d'ordre p du signal y de moyenne nulle sont donnés par :

$$C_{ab}(x) = \text{Cum}[x, \dots, x_{(p-q \text{ fois})}, \bar{x}, \dots, \bar{x}_{(q \text{ fois})}] \quad (\text{I.3})$$

Où $a = p - q$ et $b = q$

En utilisant l'équation 1.3 :

$$C_{20} = \text{Cum}[x, x] \quad C_{21} = \text{Cum}[x, \bar{x}] \quad (\text{I.4})$$

Les HOCs sont exprimés en fonction des moments d'ordre supérieur (HOMs) d'un signal. Les relations entre certains des HOC les plus couramment utilisés et les HOM sont données dans le tableau 1.2.

<i>Cumulant</i>	<i>En termes de moments</i>
C_{40}	$M_{40} - 3M_{20}^2$
C_{41}	$M_{41} - 3M_{21}M_{20}$
C_{42}	$M_{42} - 2M_{21}^2 - M_{20} ^2$
C_{60}	$M_{60} - 15M_{20}M_{40} - 30M_{20}^3$
C_{61}	$M_{61} - 5M_{40}M_{21} - 10M_{41}M_{20} + 3M_{21}M_{20}^2$
C_{62}	$M_{62} - 6M_{42}M_{21} - 8M_{41}M_{21} - M_{40}M_{22} + 6M_{22}M_{20}^2 + 24M_{20}M_{21}^2$
C_{63}	$M_{63} - 9M_{21}M_{42} + 12M_{21}^3 - 3M_{20}M_{43} - 3M_{22}M_{41} + 18M_{20}M_{21}M_{22}$

Tableau I.2 : Relations Cumulants / moments statistiques.

Le tableau ci-dessous représente les valeurs théoriques des cumulants pour des modulations M-PAM, M-PSK et M-QAM :

<i>Modulation</i>	C_{20}	C_{21}	C_{40}	C_{41}	C_{42}
2 – PAM	1.0000	1.0000	-2.0000	-2.0000	-2.0000
4 – PAM	1.0000	1.0000	-1.3600	-1.3600	-1.3600
8 – PAM	1.0000	1.0000	-1.2381	-1.2381	-1.2381
B – PSK	1.0000	1.0000	-2.0000	-2.0000	-2.0000
Q – PSK	0.0000	1.0000	0.0000	0.0000	-1.0000
8 – PSK	0.0000	1.0000	0.0000	0.0000	-1.0000
4 – QAM	0.0000	1.0000	-0.6800	0.0000	-0.6800
16 – QAM	0.0000	1.0000	-0.6800	0.0000	-0.6800
64 – QAM	0.0000	1.0000	-0.6191	0.0000	-0.6191

Tableau I.3 : Cumulants théoriques des modulations M-PAM, M-PSK et M-QAM.

I.6 Classification

L'étape qui suit l'extraction est la classification. Elle représente la partie décisionnelle de l'ensemble du processus d'identification de types de modulation. Elle a pour but de différencier les différents types de modulation.

Les systèmes de classification comportent trois étapes :

- L'apprentissage : ce processus trouve la description de l'espace des observations qui traduit le mieux l'association avec les classes correspondantes ;
- Le test : pour évaluer les performances du système ;
- La validation : afin d'estimer les performances du classifieur.

I.6.1 Séparateurs vaste marge SVM

Introduit en 1990 par Vapnik, les machines à vecteurs de support (SVM) constituent un puissant algorithme d'apprentissage automatique supervisé. Un SVM est conçu pour les problèmes de classification à réponse binaire c'est-à-dire la décision est une classe ou une autre [15].

Ce type de classifieur repose sur deux notions principales : la notion de marge maximale et la notion de fonction noyau. Le but des SVM est de trouver un séparateur entre deux classes qui soit au maximum éloigné de n'importe quel point des données d'entraînement.




Figure I.6 : Classification à deux classes avec un séparateur linéaire.




Figure I.6 : Classification à deux classes avec un séparateur non-linéaire.

I.6.2 Réseaux neurones artificiels ANN

Un réseau de neurones artificiel est un modèle informatique très répandu, dont la structure en couches est similaire à la structure en réseau des neurones du cerveau [16]. Grâce à des couches de nœuds connectés, il peut apprendre à partir de données ; il peut ainsi être entraîné à reconnaître des tendances, classer des données et prévoir des événements à venir.

Il se compose d'une couche d'entrée, d'une ou de plusieurs couches masquées et d'une couche de sortie. La connexion entre les couches est réalisée via des nœuds, ou neurones. Chaque neurone a son propre état interne interprété par la fonction d'activation. Chaque couche utilise la sortie de la couche précédente comme entrée.




Figure I.7 : Structure d'un classifieur ANN.

I.6.3 K plus proches voisins (KNN)

La méthode des k plus proches voisins KNN est l'une des méthodes de classifications les plus anciennes et les plus simples basée sur l'apprentissage paresseux (lazy learning). Cela signifie que la phase d'entraînement est assez rapide. La méthode KNN suppose que les données se trouvent dans un espace de caractéristiques [17]. L'entrée se compose des K données d'entraînement les plus proches dans l'espace de caractéristiques. Son principe pour trouver la classe d'un nouvel individu est de :

- Chercher, parmi les individus déjà classés, les K plus proches voisins de ce dernier.
- Choisir parmi les candidats trouvés, la classe qui contient le plus d'individus.

Cette méthode utilise essentiellement deux paramètres : le nombre $K \in \mathbb{N}$ qui est déterminé par l'utilisateur, et décide combien de voisins influencent la classification, et une fonction de similarité pour comparer les individus dans l'espace de caractéristiques. Pour mesurer le degré de différence entre deux individus, la notion de distance est utilisée. Il existe plusieurs types de distances parmi lesquels on trouve :

- La distance Euclidienne :

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (\text{I.5})$$

- La distance de Manhattan :

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad (\text{I.6})$$

- La distance de Minkowsky :

$$d(x, y) = (\sum_{i=1}^n |x_i - y_i|^p)^{1/p} \quad (\text{I.7})$$

Où : x, y sont des vecteurs et p un paramètre.




Figure I.8 : Exemple classificateur KNN pour $K=3$.

I.7 Conclusion

Dans ce chapitre, nous avons présenté les caractéristiques principales, l'architecture et les fonctions de base de la radio cognitive (RC) ainsi que les concepts de radio logicielle, la SDR. Nous avons détaillé la fonction de reconnaissance automatique de modulation (AMR), notamment quand elle repose sur approche de reconnaissance de tendance statistique à base d'extraction d'attributs ou de connaissances utiles sur les signaux reçus. Cette fonction AMR sera utilisée dans un récepteur cognitif d'un système MIMO à modulation spatiale, que nous décrirons dans le prochain chapitre.

CHAPITRE II

Systèmes SM-MIMO

II.1 Introduction

MIMO acronyme de ‘‘Multiple-Input Multiple-Output’’, est une technologie d’antennes apparue dans les années 80 par M. Jack Winters [18]. Utilisée pour les communications sans fil, MIMO permet des transferts de données à plus longue portée avec un débit plus élevé, en déployant plusieurs antennes au niveau de l’émetteur ainsi que du récepteur, contrairement aux systèmes classiques à une seule antenne en émission et en réception.

Dans ce chapitre, nous présentons les caractéristiques des systèmes MIMO ainsi qu’une technique récente de modulation, dite modulation spatiale (SM).

II.2 Systèmes MIMO

Les systèmes MIMO sont les systèmes de communication qui exploitent la technologie à réseaux d’antennes MIMO. Dans ces systèmes, chaque antenne émettrice devient une source d’informations différentes pour les antennes réceptrices [19]. La figure suivante illustre le principe d’un système de transmission MIMO utilisant n antennes émettrices et m antennes réceptrices.

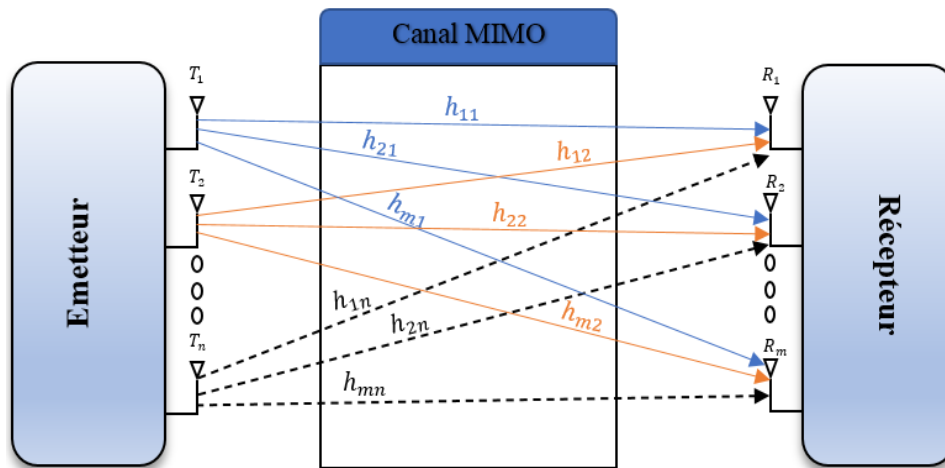


Figure II.1 : Principe système MIMO.

D’après cette figure, nous voyons que le signal reçu ($r_j(t)$, $j \in \{1, 2, \dots, m\}$) par la j -ième antenne, est la somme des convolutions de tous les signaux ($s_i(t)$, $i \in \{1, 2, \dots, n\}$) émis par les n antennes émettrices, avec les réponses impulsionnelles respectives des trajets parcourus h_{ji} :

$$r_j(t) = \sum_{i=1}^n s_i(t) \times h_{ji}(t) \quad (\text{II.1})$$

Avec concaténation de toutes les réponses impulsionnelles $h_{ji}(t)$, possibles du canal sous forme matricielle, on obtient alors la matrice de dimension $m \times n$ suivante :

$$H = \begin{bmatrix} h_{11} & h_{12} & \dots & h_{1n} \\ h_{21} & h_{22} & \dots & h_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ h_{m1} & h_{m2} & \dots & h_{mn} \end{bmatrix} \quad (\text{II.2})$$

A la réception, la résultante des signaux est donnée par :

$$r(t) = H \times s(t) + n(t) \quad (\text{II.3})$$

où $s(t) = [s_1(t), s_2(t), \dots, s_{nT}(t)]^T$, $s_i(t)$ étant le signal émis par la i -ème antenne d'émission ;

$r(t) = [r_1(t), r_2(t), \dots, r_{mR}(t)]^T$, $r_j(t)$ étant le signal reçu par la j -ème antenne réceptrice ;

H est la matrice des coefficients complexes du canal ;

$n(t)$: est un bruit blanc gaussien.

II.2.1 Notion et principe de diversité

Dans le but de lutter contre les évanouissements engendrés par les phénomènes des multi-trajets, la technique de diversité a été créée. Le principe de base consiste à ce que le récepteur dispose de plusieurs versions du signal transmis [20], reçues sur des canaux indépendants. Il existe plusieurs types de diversité [21] : temporelle, fréquentielle, spatiale, en plus des diversités anciennes (diversité angulaire, de polarisation, de diagramme.

- **La diversité spatiale MIMO** : on transmet simultanément un même message sur différentes antennes à l'émission. Les signaux reçus sur chacune des antennes de réception sont ensuite remis en phase et sommés de façon cohérente.
- **La diversité spatio-temporelle** : combinaison des techniques de diversité, spatiale et temporelle qui consiste à envoyer des versions du signal différées dans le temps et dans l'espace via des antennes émettrices différentes. Cela engendre des gains de diversité et de multiplexage.
- **Le multiplexage spatial MIMO** : chaque message est découpé en sous-messages. On transmet simultanément les sous-messages différents sur chacune des antennes d'émission. Les signaux reçus sur les antennes de réception sont réassemblés pour reformer le message entier d'origine.

- **Le MIMO -Beamforming** : on utilise le réseau d'antenne MIMO pour contrôler et focaliser le faisceau d'onde radio vers une direction précise. Cette technique permet à la fois d'étendre une couverture radio et de limiter les interférences entre utilisateurs et la pollution électromagnétique environnante.

II.2.2 Configurations MIMO

Selon le nombre d'antennes à l'émission et la réception, on distingue plusieurs configurations (systèmes). Chaque architecture utilise différentes fonctions de traitement du signal telles que la technique de combinaison, le codage spatio-temporel, le multiplexage spatial.

II.2.2.1 Système SISO (Single Input Single Output)

Architecture basique, utilise une antenne en émission et une en réception. La capacité du canal est donnée par [22, 23] :

$$C_{SISO} = W \times \log_2\left(1 + \frac{P}{W \times N_0}\right) \quad (\text{II.4})$$

Où W est la bande passante donnée en Hz ; P la puissance du signal en Watt et N_0 la densité spectrale de puissance du bruit calculé en W/Hz .

En normalisant la capacité avec la bande passante :

$$C_{SISO} = \log_2(1 + \rho) \quad (\text{II.5})$$

Avec ρ est le rapport SNR.

II.2.2.2 Système SIMO (Single Input Multiple Output)

Cette technique utilise une antenne à l'émission, et plusieurs à la réception. Elle permet de lutter contre le phénomène d'évanouissement. Sa capacité est exprimée comme suit [22, 23] :

$$C_{SIMO} = W \times \log_2\left(1 + N_R^2 \times \frac{P}{W \times N_0}\right) \quad (\text{II.6})$$

N_R étant le nombre d'antennes réceptrices.

Avec normalisation de la capacité avec la bande passante :

$$C_{SIMO} = \log_2(1 + N_R^2 \times \rho) \quad (\text{II.7})$$

II.2.2.3 Système MISO (Multiple Input Single Output)

Dans ce système, N_T antennes en émissions sont déployées et une seule en réception est utilisée. La puissance émise sur chaque antenne est divisée sur les N_T antennes d'émission. Sa capacité moyenne est donnée par [22, 23] :

$$\bar{C}_{MISO} = \log_2(1 + \rho) \quad (\text{II.8})$$

Nous constatons que les capacités moyennes des systèmes SISO et MISO sont identiques (II.5 et II.8). La différence réside dans la probabilité d'évanouissement lors du phénomène des multi-trajets :

$$Pr_{MISO} < Pr_{SISO} \quad (\text{II.9})$$

Pr_{MISO} est la probabilité d'évanouissement dans le système MISO, Pr_{SISO} celle d'un système SISO.

II.2.2.4 Système MIMO (Multiple Input Multiple Output)

Dans un système à N_T antennes émettrices et N_R antennes réceptrices, sa capacité est :

$$C_{MIMO} = \log_2 \left(\det \left[I_{N_R} + \frac{\rho}{N_T} HH^* \right] \right) \quad (\text{II.10})$$

Où I_{N_R} est la matrice identité de taille N_R , H la matrice des coefficients du canal (H^* étant sa transposée conjuguée).

II.2.3 Algorithmes de réception associés aux systèmes MIMO

Après l'envoi du signal sur chaque antenne émettrice à travers le canal, le récepteur utilise différentes techniques afin de récupérer et de détecter efficacement les symboles transmis. Ces techniques sont divisées en deux classes : linéaires et non-linéaires. Les moins complexes sont les récepteurs linéaires basés sur le critère de forçage à zéro (ZF), la minimisation de l'erreur quadratique moyenne (MMSE).

- **Récepteur linéaire à Forçage à zéro (ZF)**

Cet algorithme simple donne une approximation du symbole reçu en se basant sur la minimisation de l'erreur [24].

$$\hat{x} = (H^T H)^{-1} \times H^T \times y \quad (\text{II.11})$$

Pour des matrices H à coefficients complexes :

$$\hat{x} = (H^H H)^{-1} \times H^H \times y \quad (\text{II.12})$$

Avec H^H est la matrice hermitienne de H .

$$H^H = \overline{H}^T \quad (\text{II.13})$$

L'inconvénient majeur d'un récepteur à forçage à zéro, réside dans le fait qu'il amplifie le bruit dans les environnements à fort phénomène d'évanouissement.

- **Récepteur linéaire à minimisation de l'erreur quadratique moyenne MMSE**

Une autre approche linéaire plus robuste au bruit pour estimer le vecteur symbole reçu x , consiste à minimiser l'erreur quadratique moyenne entre le vecteur de données x et son estimée \hat{x} . Le MMSE est utilisé dans les systèmes MIMO, afin de réduire les interférences inter-symbole (ISI) ainsi que le bruit. L'estimation est donnée par la formule suivante [24] :

$$\hat{x} = P_x(P_x H^H H + \sigma_n^2 I)^{-1} \times H^H y \quad (\text{II.14})$$

Où P_x est la puissance du symbole de donnée transmis.

Pour un SNR important l'équation (2.14) devient :

$$\hat{x} = (H^H H)^{-1} \times H^H y \quad (\text{II.15})$$

D'après l'équation (II.15), l'algorithme ZF est un cas exceptionnel de MMSE.

- **Récepteur à annulations successives d'interférences ordonnées (V-BLAST)**

Ce récepteur utilise l'algorithme V-BLAST qui repose sur les détections linéaires (ZF, MMSE) et non-linéaires (ML) [24]. Son principe consiste à réaliser une première détection, du signal le plus fort. On régénère le signal reçu de cet utilisateur à partir de cette décision. Ensuite, le signal régénéré est soustrait du signal reçu et, avec ce nouveau signal, on procède à la détection du deuxième utilisateur le plus puissant, puisqu'on s'est déjà débarrassé du premier et ainsi de suite. L'inconvénient majeur de cet algorithme est qu'une fois qu'une mauvaise décision a été prise sur la valeur d'un symbole, cela entraîne aussitôt une mauvaise estimation des symboles suivants.

II.3 Modulation spatiale

La technique MIMO est l'une des principales technologies utilisées pour les communications sans fil de nos jours. Elle offre un compromis entre des débits de données plus élevés et des performances d'erreur supérieures. Elle tient compte de l'utilisation de toutes les antennes émettrices au niveau de l'émetteur, ce qui réduit l'optimisation de l'efficacité spectrale et énergétique. Pour venir à bout de ces inconvénients

en plus de la complexité et du coût élevé des systèmes MIMO, une nouvelle technique de modulation a été introduite : la modulation spatiale (SM).

II.3.1 Principe de la modulation SM

Le principe général de la SM est d'ajouter des bits d'informations supplémentaires qui indiquent l'indice de l'antenne active. En termes de constellation, ces bits sont représentés sur une troisième dimension appelée : constellation spatiale. Au niveau de l'émetteur, un flux binaire est généré [25], décomposé en paquet de k bits tel que :

$$k = \log_2(N_T) + \log_2(M) \quad (\text{II.16})$$

N_T étant le nombre d'antennes émettrices et M l'ordre de modulation.

Ce flux est constitué de deux sous-blocs : Le sous-bloc de $\log_2 N_T$ bits identifiant l'antenne émettrice utilisée, et le second de $\log_2 M$ bits désignant le symbole à transmettre.

La figure ci-dessous représente le diagramme de constellation SM pour $N_T = 4$ et $M = 4$.




Figure II.2 : Diagramme de constellation de SM.

Le tableau suivant représente les différentes combinaisons possibles pour $N_T = 4$ et $M = 4$:

<i>Bits</i>	<i>Bits spatiaux</i>	<i>Index TA</i>	<i>Bits symbole</i>	<i>Symboles</i>
0000	00	Tx_0	00	$+1 + i$
0001	00	Tx_0	01	$-1 + i$
0010	00	Tx_0	10	$-1 - i$
0011	00	Tx_0	11	$+1 - i$
0100	01	Tx_1	00	$+1 + i$
0101	01	Tx_1	01	$-1 + i$
0110	01	Tx_1	10	$-1 - i$
0111	01	Tx_1	11	$+1 - i$
1000	10	Tx_2	00	$+1 + i$
1001	10	Tx_2	01	$-1 + i$
1010	10	Tx_2	10	$-1 - i$
1011	10	Tx_2	11	$+1 - i$
1100	11	Tx_3	00	$+1 + i$
1101	11	Tx_3	01	$-1 + i$
1110	11	Tx_3	10	$-1 - i$
1111	11	Tx_3	11	$+1 - i$

Tableau II.1 : Exemple de modulation SM pour $N_T = 4$ et $M = 4$.

À la réception, un algorithme de démodulation est utilisé. Les symboles sont démodulés en détectant l'antenne active d'abord, puis à partir de cette dernière le symbole modulé est détecté. D'autres techniques de démodulation ont été proposées récemment pour garantir un compromis complexité et performance [26].

II.3.2 Association SM-OFDM

L'idée de base de la modulation multi-porteuse par répartition orthogonale en fréquence OFDM est de diviser le flux binaire transmis en plusieurs sous-flux différents et de les envoyer sur de nombreux sous-canaux différents. Typiquement, les sous-canaux sont orthogonaux dans des conditions de propagation idéales, auquel cas la modulation à porteuses multiples est souvent appelée multiplexage par répartition orthogonale de fréquence (OFDM) [27].

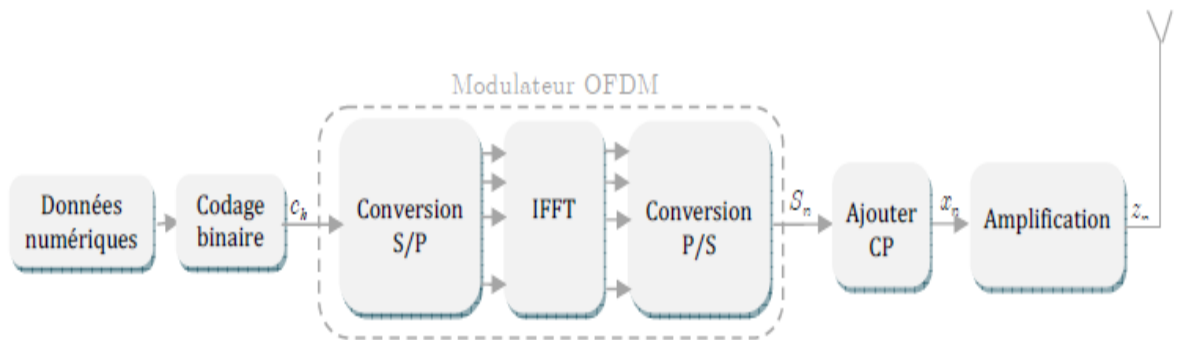


Figure II.3 : Schéma-bloc d'un émetteur OFDM avec une IFFT.

Les systèmes OFDM ont pour principe la répartition des symboles complexes C_k sur N_k sous-porteuses. Les symboles OFDM transmis sont de durée T_s . Dans la figure (1), les C_k sont des symboles complexes (de période T_u) générés à partir d'éléments binaires par une constellation souvent d'une modulation QAM (Quadratique Amplitude Modulation) ou PSK (Phase Shift Keying) à plusieurs états, en fonction de la vitesse de transmission demandée.

La construction particulière du signal modulé par projection sur une base orthogonale de sous-porteuses conduit à une densité spectrale composée de la somme des N_p densités spectrales des sous-porteuses. Il en résulte, une forme de densité spectrale, typique des signaux OFDM avec une modulation 16-QAM. Après l'IFFT, un préfixe cyclique (CP) qui consiste en une copie de la fin du symbole OFDM à transmettre est placée dans le but de combattre l'effet de dispersion.

La démodulation à la réception se fait par une FFT du signal reçu échantillonné au rythme. Ce processus est illustré par la figure ci-dessous.

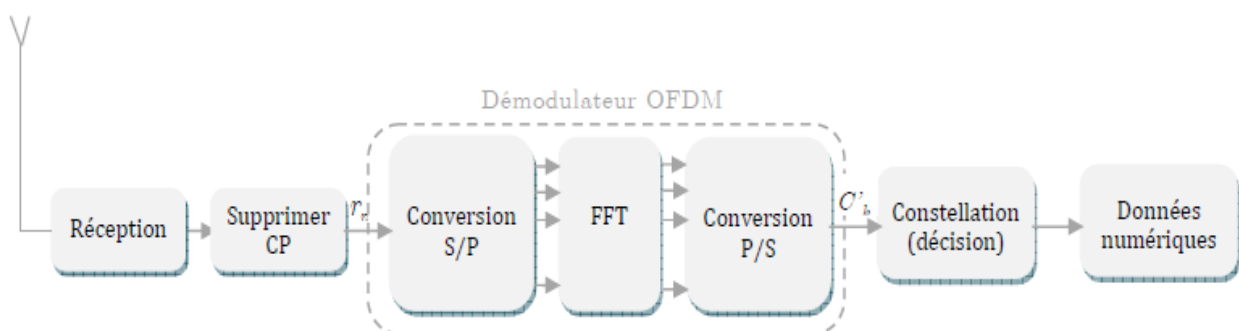


Figure II.4 : Schéma-bloc d'un récepteur OFDM avec une FFT.

La suppression du préfixe CP permet de restituer l'orthogonalité entre les sous-porteuses. De plus, comme ce préfixe est une copie des échantillons de fin de symbole OFDM, il peut également être exploité en réception pour la synchronisation temporelle du signal OFDM.

II.4 Conclusion

Dans ce chapitre, nous avons décrit la technologie MIMO de déploiement de réseaux d'antennes à l'émission et à la réception afin d'améliorer la qualité du rapport, le débit de transmission et donc une meilleure qualité de service. Nous avons aussi explicité un schéma modulation spatiale qui améliore les performances des systèmes MIMO avec une faible complexité.

CHAPITRE III

Introduction aux Réseaux de Neurones

Artificiels (RNA)

III.1 Introduction

L'évolution technologique durant les dernières années a permis aux scientifiques d'élaborer et de perfectionner des méthodes pour différents domaines. L'évolution des ordinateurs en particulier et la formidable capacité d'intégration de composants atteinte à nos jours, ont permis une grande vitesse de calcul et une grande capacité mémoire. Parmi ces méthodes, il existe une méthode qui est utilisée dans plusieurs domaines de recherches et de différentes manières, d'une manière complètement soft en s'aidant d'un ordinateur ou d'une manière hard en utilisant les circuits intégrés [28]. Cette méthode est celle des réseaux de neurones artificiels (RNA).

Ce chapitre décrit le formalisme mathématique des réseaux de neurones artificiels, à base d'une analogie avec le fonctionnement du cerveau humain. Nous décrivons les types de réseaux existants, leurs architectures et les fonctions ils ont été développés.

III.2 Historique des RNA

- 1890 : Le concept de mémoire associative a été introduit par W. James, ce dernier proposa une loi connue sous le nom de loi de Hebb ;
- 1943 : J. Mc Culloch et W. Pitts laissent leurs noms à une modélisation du neurone biologique (un neurone au comportement binaire). Ce sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes (tout au moins au niveau théorique) ;
- 1949 : D. Hebb, physiologiste américain démontre à partir d'une expérience le conditionnement chez l'animal par les propriétés des neurones eux-mêmes ;
- 1958 : Apparition du premier réseau de neurone artificiel (le perceptron), grâce aux travaux de Rosenblatt [29].
- 1969 : M. Minsky et S. Papert publient un ouvrage qui met en exergue les limitations théoriques du perceptron, ce qui entraîne alors un abandon financier des recherches dans le domaine.
- Début des années 80 : l'intérêt de ce domaine raviva grâce aux travaux de Hopfield qui démontra l'intérêt d'utiliser les réseaux récurrents (feedback) pour la modélisation des processus, et la création en parallèle d'un algorithme de rétropropagation par Werbos qui ne sera popularisé qu'en 1986 par Rumelhart.

III.3 Modèle Biologique des neurones

Un réseau de neurone artificiel est un modèle de calcul inspiré du modèle biologique, c'est-à-dire du cerveau humain. Ce dernier est composé d'un grand nombre de cellules nerveuses appelées neurones, et formées d'une partie cellulaire et d'une partie de noyau. La partie cellulaire, nommée *Somma*, se ramifie pour former les *dendrites* [30], par lesquelles l'information s'achemine vers le corps du neurone (*le Somma*).

L'information traitée par le neurone chemine ensuite le long de l'axone (unique) pour être transmise aux autres neurones. Les neurones ne sont pas directement connectés entre eux. La jonction ou l'espace qui sépare l'axone d'un neurone et les dendrites du neurone voisin est appelé « Synapse ».




Figure III.1 : Exemple de neurone biologique.

Les synapses possèdent une sortie de « *mémoire* » qui leur permet d'ajuster leur fonctionnement en fonction de leur historique d'activation entre deux neurones. Cette plasticité est à l'origine des mécanismes d'apprentissage.

III.4 Modèle formel des neurones

De façon générale, comme nous venons de le voir, un neurone biologique est caractérisé par :

- Des synapses, qui sont les points de connexions avec les autres neurones, fibres nerveuses.
- Les dendrites : les entrées du neurone.
- L'axone, le chemin que l'information prend pour passer vers d'autres neurones.
- Le noyau qui active la sortie en fonction des stimuli en entrée.

Par analogie avec ce dernier, le neurone formel (voir figure 3.2) est une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique. C'est une fonction non linéaire, paramétrée, à valeurs bornées, il se caractérise par un état interne, des signaux d'entrée $X = \{x_1, x_2, \dots, x_n\}$ et une fonction de transition ou d'activation f comme suit :

$$f(s) = f(\sum_{i=1}^n w_i x_i + b) \quad (\text{III.1})$$

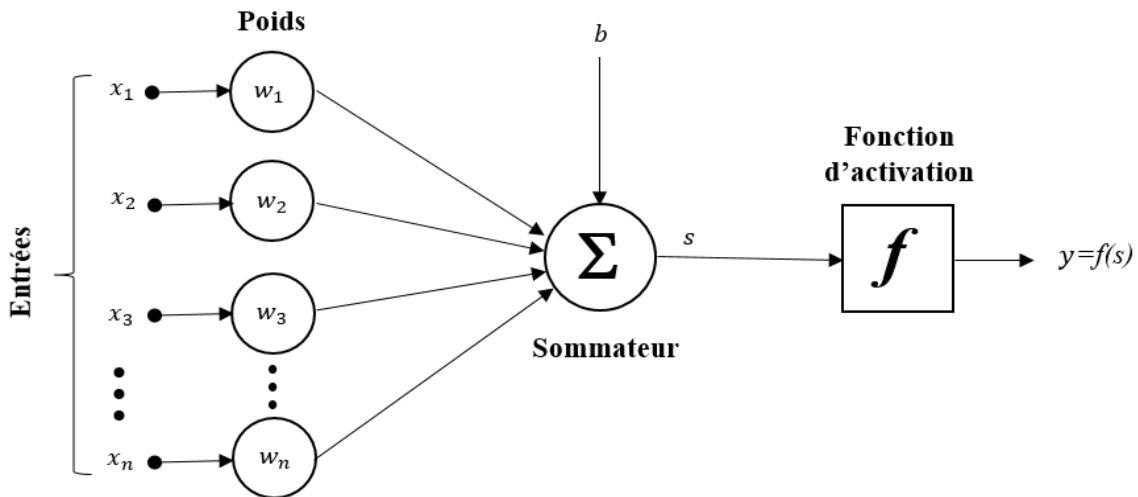


Figure III.2 : Modèle d'un neurone artificiel.

La figure ci-dessus illustre un modèle de neurone artificiel tel que [31] :

$\{x_1, x_2, x_3, \dots, x_n\}$: sont les entrées ;

$\{w_1, w_2, w_3, \dots, w_n\}$: sont les poids de chaque entrée ;

b : désigne le biais ;

s : la somme pondérée des entrées.

La fonction d'activation (ou fonction de seuillage, ou encore fonction de transfert) est une combinaison des signaux d'entrée. Elle sert à introduire une non-linéarité dans le fonctionnement du neurone.

III.4.1 Les types d'apprentissage des réseaux de neurones

Pour l'être-humain, la notion d'apprentissage est une procédure cognitive qui consiste à ce qu'un individu réalise de manière autonome une tâche donnée, typiquement à partir d'exemples. Pour les RN, c'est une phase de développement du réseau. L'apprentissage neuronal fait appel à des exemples qu'il va étudier jusqu'à atteindre la sortie désirée. Durant cette phase, les poids synaptiques w_i seront modifiés. En gros, l'apprentissage n'est rien d'autre qu'une action de mise à jour des poids des connexions dans le

but d'atteindre la sortie du réseau pour les exemples présentés en entrée. On peut distinguer trois types d'apprentissage [32] :

- **L'apprentissage supervisé** : basé sur le fait de fournir au réseau un ensemble de données étiquetées (entrée, sortie associée). Les paramètres du réseau sont alors ajustés jusqu'à minimiser l'erreur de sortie qui est fonction de la sortie prédite et de la sortie désirée.
- **L'apprentissage par renforcement ou semi-supervisé** : inspiré de la façon dont les animaux de compagnie sont éduqués, en leur offrant une friandise quand ils font une bonne action, ce type d'apprentissage est une approche utilisée dans des problèmes de planification à travers le temps. Deux réseaux sont utilisés : un réseau d'action et un réseau d'évaluation qui joue le rôle de superviseur et génère un signal d'avertissement à chaque mauvaise décision. C'est ce signal qui est utilisé pour entraîner le réseau d'action.
- **L'apprentissage non supervisé** : dans cet algorithme, les exemples d'apprentissage ne sont que des valeurs d'entrée et non des couples (entrée, sortie associée) comme dans le cas de l'apprentissage supervisé. 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.4.2 Règles d'apprentissage

L'apprentissage d'un RNA se base sur des règles d'apprentissage. Nous citons ci-après les trois règles les plus répandues :

- La règle de Hebb, établie en 1949. Cette loi ne s'applique qu'aux connexions entre neurones Elle permet de modifier la valeur des poids synaptiques en fonction de l'activité des unités qui les relie. Cette règle stipule que lorsque deux neurones sont excités conjointement, la connexion qui les lie est renforcée (connexion excitatrice) sinon elle est affaiblie (connexion inhibitrice).
- La règle delta qui calcule la différence entre la valeur prédite et la valeur désirée pour ajuster les poids synaptiques. Elle emploie la fonction d'erreur MSE, pour l'ajustement des poids.
- La règle de rétropropagation de Rumelhart, Hinton et Williams, inventée en 1986. Utilisée pour ajuster les poids de la couche d'entrée à la couche cachée, elle est aussi considérée comme une généralisation de la règle delta pour des fonctions d'activation non linéaire et pour des réseaux multicouches. Elle consiste à rétro-propager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés. L'algorithme rétropropagation du gradient de l'erreur est généralement utilisé. Ce dernier consiste à corriger les erreurs selon l'importance de chaque poids qui a participé à la réalisation de ces erreurs : les poids synaptiques qui contribuent à engendrer

une erreur importante se verront modifiés de manière plus significative que les poids qui ont engendré une erreur marginale.

III.4.3 Architecture des réseaux neurones

Depuis leur création, les réseaux ANN sont devenus quasi-présents dans plusieurs domaines. Ils peuvent être définis comme étant des modèles statistiques qui peuvent apprendre à estimer les paramètres d'un ensemble de données en utilisant un nombre d'exemples, basés sur une analogie avec le cerveau humain. Un réseau de neurones artificiel est constitué d'un ensemble de neurones interconnectés entre eux à l'aide d'un ensemble de connexions pondérées [33]. Selon la façon dont les neurones sont interconnectés entre eux, on distingue deux grandes classes de RNA : Les réseaux feed-forward et les réseaux feedback.

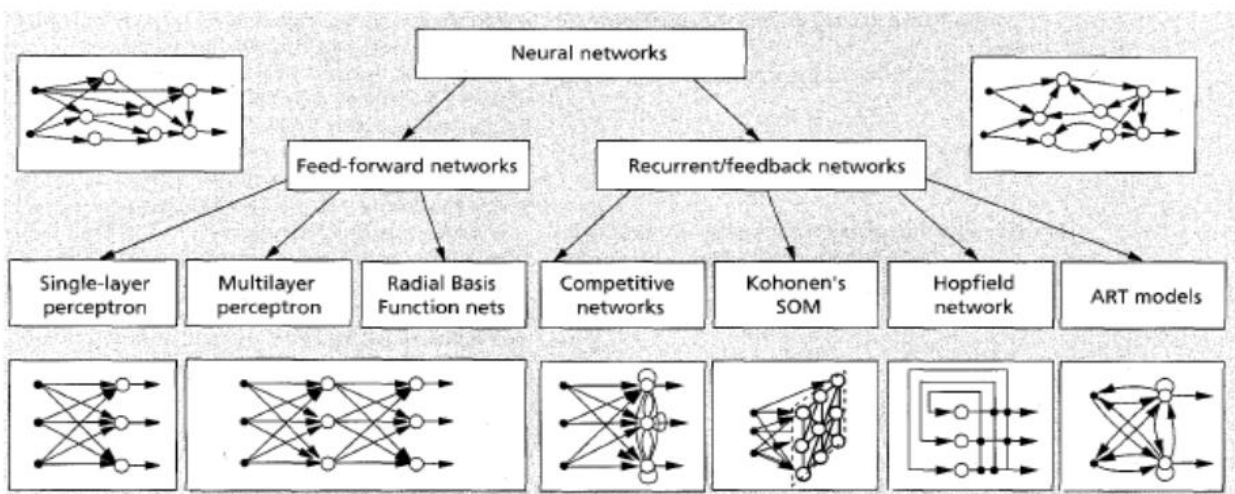


Figure III.3 : Topologies des Réseaux de Neurones Artificiels.

- **Les réseaux feed-forward** : aussi appelés réseaux à couches, l'information s'y propage de couche en couche sans retour en arrière possible. Ils peuvent se diviser en réseaux sans couches cachées ou avec couches cachées.

Les plus simples sont les réseaux monocouches (sans couches cachées). Leur inconvénient est qu'ils ne sont utilisables que pour résoudre des problèmes de classification et d'approximation [83]. Le Perceptron monocouche est l'exemple classique pour ce type de réseau. C'est un modèle très simple, il ne dispose que de deux couches : une couche d'entrée et une couche de sortie [34].

L'autre type des réseaux feed-forward sont les réseaux multicouches (ou Perceptron Multi Couches) [34]. Ce dernier est composé, en plus des couches d'entrée et de sortie, d'une ou plusieurs couches

cachées. Ils ont été conçus afin de remédier aux inconvénients du perceptron monocouche. La figure 3.5 ci-dessous illustre un exemple de PMC à deux couches cachées.




Figure III.4 : Exemple réseau perceptron à deux entrées.




Figure III.5 : Exemple de réseaux PMC.

- **Les réseaux feedback :** ce sont des réseaux qui permettent des connexions arbitraires entre les neurones de toutes les couches ; lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ. Ils constituent la deuxième grande classe de RNA. Trois classes importantes de ce type sont les plus utilisées [35] :
 - Les réseaux récurrents à couches (le réseau d'Elman et le réseau de Jordan) ;
 - Les réseaux à compétition (réseaux ART et réseaux de Kohonen) ;
 - Les réseaux à connexions symétriques (réseaux de Hopfield).

La figure III.6 montre la structure d'un réseau de Jordan. C'est le premier réseau récurrent inventé.

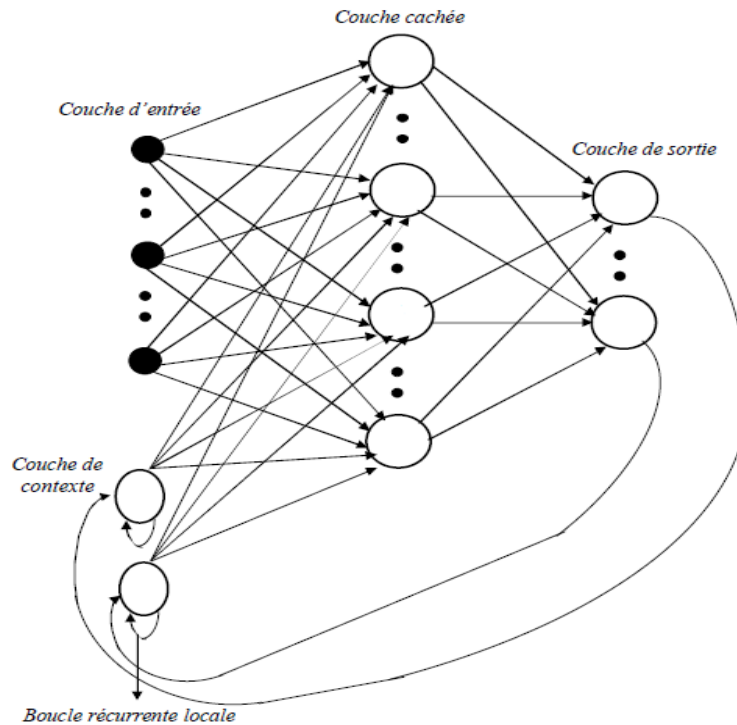


Figure III.6 : Réseau de Jordan.

Le but de ce réseau est d'effectuer une séquence d'actions par rapport à une tâche donnée par l'utilisateur. La tâche est constante durant l'exécution de la séquence ; le réseau doit toutefois retenir sa position dans la séquence. Pour mener la tâche à bien, il lui faut donc une mémoire représentée par une couche appelée « couche de contexte », sa tâche est de retenir l'état du réseau au temps précédent et sa propre activation par une boucle récurrente locale. Le nombre de neurones de cette couche est fonction du nombre de neurones de sortie qui sont reliés entre eux. Il en résulte que la couche de contexte retient un historique des événements passés.




Figure III.7 : Schéma général de réseaux Elman.

Le réseau récurrent d'Elman introduit en 1990 et représenté ci-dessus, est similaire au réseau Jordan [36] à la différence qu'au lieu de boucler ses sorties sur ses entrées, il boucle sa couche cachée sur elle-même. Par conséquent la couche de contexte, a pour rôle de retenir l'historique d'activation de la couche cachée. Un schéma général de ce réseau est représenté à la figure III.7.

Les réseaux à compétition sont composés d'une couche d'entrées et d'une couche de neurones de sortie en compétition. Ce type de réseaux suit une certaine logique, décrite ci-dessous :

« Une donnée d'entrée est présentée au réseau, provoquant des réponses variées dans les neurones de sortie. La compétition s'installe alors entre ces derniers, et prend la forme d'un combat d'influence qui doit éventuellement se stabiliser grâce à la force des liens inhibiteurs. A la fin de la compétition, les neurones de sortie les plus activés sont déclarés "vainqueurs" ».

On peut citer comme exemple les réseaux ART (Adaptive Resonance Theory) et les réseaux de Kohonen (Self-organisation mapping).

Les réseaux à connexions symétriques, sont beaucoup plus pratiques. Il est possible de comprendre un système complexe, non pas en s'attardant sur le comportement individuel de ses composants, mais en étudiant le comportement collectif du système dans son ensemble. Un exemple de ce type de réseau est le réseau Hopfield.

III.4.4 Fonction d'activation

La fonction d'activation (ou encore fonction de transfert) est une transformation linéaire ou non linéaire. Elle calcule la valeur de l'état du neurone. C'est cette valeur qui sera transmise aux neurones suivants. Beaucoup de fonctions d'activation ont été introduites vu la variété des modèles RNA, on y trouve :

- **Le modèle à seuil** : ce modèle est très proche et conforme à la réalité biologique mais il pose des problèmes d'apprentissage.
- **Les modèles linéaires et sigmoïdaux** : ces modèles sont très adaptés aux algorithmes d'apprentissage comme celui de rétro propagation du gradient car leur fonction de transition est différentiable.

Le tableau (III.1) présente les différentes fonctions d'activation les plus utilisées.

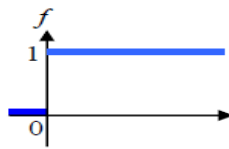
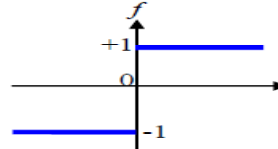
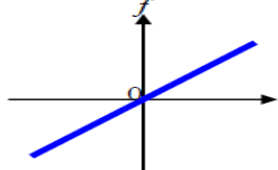
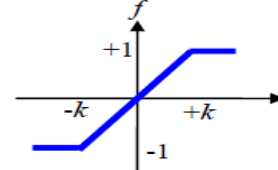
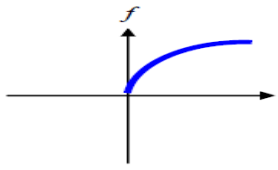
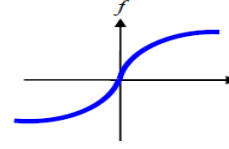
Catégorie	Type	Equation	Allure
Seuil	Binaire (Heaviside)	$f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$	
	Signe	$f(x) = \begin{cases} +1, & x < 0 \\ -1, & x \geq 0 \end{cases}$	
Linéaire	Identité	$f(x) = x$	
	Saturation	$f(k, x) = \begin{cases} -1, & x < -1/k \\ 1, & x \geq 1/k \\ kx, & \text{sinon} \end{cases}$	
Sigmoïde	Positive (logistique)	$f(k, x) = \frac{1}{1 + e^{-kx}}$	
	Symétrique (Type tanch)	$f(k, x) = \frac{2}{1 + e^{-kx}} - 1$	

Tableau III.1 : Fonctions d'activation importantes

III.5 Algorithme de rétropropagation

L'algorithme de rétropropagation permet de réaliser un apprentissage du réseau de neurones. Il est conçu pour entraîner les réseaux de propagation composés de deux couches de neurones ou plus, et connectés de telle façon que les sorties d'une couche deviennent les entrées de la couche suivante. Le terme rétropropagation du gradient provient du fait que l'erreur calculée en sortie est transmise en sens inverse vers l'entrée. Il est responsable de la mise à jour des poids du réseau dans le but de réduire l'erreur du réseau.

L'erreur quadratique moyenne totale (pour tous les m neurones de sortie) représentant la performance du réseau est définie par [37] :

$$E = \frac{1}{N} \sum_{l=1}^N \sum_{j=1}^m e_{j,l}^2 \quad (\text{III.2})$$

Avec $e_{j,l}$ est l'erreur commise sur le j^{eme} neurone de sortie et l est l'exemple de la base d'apprentissage:

$$e_{j,l} = d_{j,l} - y_{j,l} \quad (\text{III.3})$$

III.5.1 Algorithme d'apprentissage d'un réseau monocouche (sans couche cachée)

Dans le cas d'un perceptron à une couche, l'expression de l'évolution des poids est assez simple. En effet, il repose sur le calcul du gradient de E par rapport à chaque poids ($w_{j,i}$) de la couche de sortie. Ainsi, ces poids sont mis à jour de la façon suivante :

- a. Initialisation des poids à des valeurs aléatoires de faible grandeur ;
- b. Propager l'entrée à travers le réseau et calculer les sorties y_j ;
- c. Calculer l'évolution des poids au cours d'une itération :

$$\Delta w_{j,i} = -2\mu \sum_{l=1}^N e_{j,l} f_1'(W^1 \times x_l) x_l \quad (\text{III.4})$$

Où μ représente le pas d'apprentissage.

- d. Mettre à jour chaque poids synaptique du réseau :

$$w_{j,i}(k+1) = w_{j,i}(k) + \Delta w_{j,i}(k) \quad (\text{III.5})$$

- e. Retourner à l'étape 2 tant que l'erreur est trop grande.

III.5.2 Algorithme d'apprentissage d'un réseau multicouches (MLP)

Dans un perceptron multicouche, il faut tenir compte de l'influence de plusieurs couches dans le calcul du gradient. Les différentes étapes de cet algorithme sont citées ci-dessus :

- a. Initialisation des poids à des valeurs aléatoires de faible grandeur,
- b. Propager les entrées x_n à travers le réseau,
- c. Pour chaque couche cachée (k), calculer l'évolution des poids au cours d'une itération :

$$\Delta w_{j,i}^k = -2\mu \sum_{l=1}^N e_{j,l}^k f'(W^k \times y_l^{k-1}) y_l^{k-1} \quad (\text{III.6})$$

- d. Mettre à jour chaque poids synaptique du réseau :

$$w_{j,i}(k+1) = w_{j,i}(k) + \Delta w_{j,i}(k) \quad (\text{III.7})$$

Retourner à l'étape 2 tant que l'erreur est trop grande.

Voici quelques-uns des avantages de l'algorithme de rétropropagation :

- Efficace en termes de mémoire : Par rapport aux autres algorithmes d'optimisation tel que l'algorithme génétique, Il utilise moins de mémoire pour le calcul des dérivées.
- L'algorithme de rétropropagation est rapide, en particulier pour les réseaux de petite et moyenne taille.
- Cet algorithme est suffisamment générique pour fonctionner avec différentes architectures de réseau, comme les réseaux de neurones convolutifs, les réseaux antagonistes génératifs, les réseaux entièrement connectés.

III.6 Applications des ANN

Depuis leur apparition, les réseaux de neurones ont été largement utilisés dans plusieurs domaines dont le nombre ne cessent de croître avec le temps. On peut citer [38] :

- Les prévisions météorologiques ;
- Les applications de reconnaissance des formes, la reconnaissance de la parole ou reconnaissance automatique d'image ;
- Le traitement du signal ;
- La Robotique (pilotage automatique des véhicules autonomes) ;
- La fouille de données (extraction des connaissances et les problèmes d'optimisation et de classification).

Le tableau ci-dessous donne les types de réseaux utilisés pour divers domaines :

Domaine d'application	Type de RNA
Reconnaissance de formes	MLP, Hopfield, Kohonen
Mémoire Associatives	Hopfield, MLP recurents, Kohonen
Optimisation	Hopfield, ART, CNN
Approximation de fonction	MLP, RBF
Modélisation et control	MLP, MLP récurrent, FLN
Traitement d'images	CNN, Hopfield
Classification et Clustering	MLP, Kohonen, RBF, ART, PNN

Tableau III.2 : Type de réseau utilisé pour chaque domaine.

III.7 Avantages et inconvénients

Les Réseaux de Neurones Artificiels ont plusieurs avantages tels que :

- La possibilité d'apprendre et de généraliser les connaissances acquises.
- Le traitement parallèle et rapide des informations.
- Facilement extensibles.
- Facilité d'utilisation.

Néanmoins, ces derniers souffrent de certaines limites dont on peut citer :

- Difficulté de définir l'architecture et le type adéquat du réseau à pour un problème donné.
- Une mauvaise initialisation des poids initiaux du réseau peut conduire à un blocage d'apprentissage mais aussi à la non-convergence du réseau vers la solution désirée.
- Un mauvais choix d'une fonction d'erreur pourra amener à une mauvaise optimisation du réseau.

III.8 Conclusion

Dans ce chapitre nous avons introduit les réseaux de neurones artificiels, basés sur le modèle biologique du cerveau humain. Nous avons décrit les processus d'apprentissage permis par ces réseaux et donné les architectures de certains types de réseaux RNA. Utilisés pour des tâches de classification et de régression dans divers domaines d'applications tels que la robotique, le traitement de signal, l'aviation..., ces réseaux sont caractérisés par de fortes capacités d'apprentissage et de généralisation. Dans la partie suivante, nous utiliserons ce type de réseaux afin de réaliser à l'aide du logiciel MATLAB, une classification (ou reconnaissance) de différents types de modulation.

CHAPITRE IV

***Performances SM-MIMO &
Classification Automatique de
Modulations (AMC)***

IV.1 Introduction

La reconnaissance automatique de modulation (AMR) est une application cruciale dans diverses applications notamment dans un contexte cognitif où le récepteur doit constamment adapter ses fonctions selon son environnement RF. Sauf qu'une bonne conception du système de communication est primordiale pour une bonne reconnaissance et nécessite donc une étude technique à l'avance et une estimation préalable des performances.

Nous réservons justement ce dernier chapitre à l'évaluation dans une première phase, des performances de systèmes sans fil associant la modulation spatiale à la technologie MIMO, et dans une seconde phase, aux résultats AMR. Cette tâche est organisée en deux étapes, d'abord une extraction des caractéristiques pertinentes des signaux reçus (statistiques d'ordre supérieur des symboles numériques) puis une classification automatique des types de modulation (AMC) à base d'un réseau de neurones artificiel RNA. Toutes nos simulations ont été réalisées sous l'environnement MATLAB.

IV.2 Évaluation des performances de systèmes SM-MIMO

Nous considérons dans nos simulations diverses configurations de systèmes SM-MIMO et divers types et ordres de modulation (M-PSK, M-QAM) dont nous évaluerons les performances en termes de différentes métriques.

IV.2.1 Métriques de performances utilisées

Pour l'évaluation des performances de nos systèmes, nous avons retenu les mesures du BER, de la capacité de transmission et de l'efficacité spectrale. Ces mesures sont des critères de quantification des transmissions numériques notamment pour le choix du type de modulation des signaux ou le choix d'une configuration antennaire à l'émission et à la réception.

- **Taux d'erreur binaire (BER) :** Ce taux est quantifié par le rapport du nombre de bits erronés à la réception au nombre total de bits transmis ;
- **Capacité du canal de transmission :** C'est le débit maximum possible de la transmission en fonction de la bande de fréquence utilisée et du rapport RSB ;
- **Rapport signal sur bruit (RSB ou SNR) :** Ce rapport généralement mesuré en décibel, est un indicateur de la qualité de la transmission d'une information, pour quantifier la quantité de bruit contenue dans le signal d'un canal de transmission :

$$\left(\frac{S}{B}\right)_{db} = 10 * \log\left(\frac{P_s}{P_B}\right) \quad (IV.1)$$

où P_s est la puissance du signal et P_B la puissance du bruit.

- **Efficacité spectrale (SE) :** C'est le rapport du débit binaire utile à la bande passante occupée par le signal transmis. Il est mesuré en bits/s/Hz comme le montre l'équation ci-dessous :

$$\eta = \frac{D}{B} \quad (\text{IV.2})$$

D : représente le débit binaire exprime en *bit/s*;

B : représente la largeur de la bande occupée par le signal en *Hz*.

IV.2.2 Paramètres de simulation

Dans nos simulations, nous avons considéré un système de communication dans un canal Rayleigh combinant l'algorithme de modulation spatiale SM avec un codage OFDM (SM-OFDM conventionnelle). Les résultats numériques que nous présenterons sont basés sur un assortiment d'intérêt des modulations $\theta = \{2\text{-PSK}, 4\text{-PSK}, 16\text{-PSK}, 4\text{-QAM}, 16\text{-QAM}, 64\text{-QAM}, 128\text{-QAM}\}$. Pour faciliter l'évaluation de nos métriques de performances, la méthode d'estimation de Monte Carlo est utilisée [10]. Cela a exigé un nombre important d'échantillons pour chaque type de modulation (1024 symboles) et pour chaque valeur de SNR ($\{-15, 25\}$ avec un pas de 5 dB). Au niveau de la réception, plusieurs types d'algorithmes permettent la détection du signal. Les résultats de simulation sont explicitement illustrés et développés dans la suite du document.

Ci-dessous, les différents paramètres utilisés pour configurer notre environnement MATLAB :

- Le type de modulation utilisé : QAM et PSK.
 $M - QAM = [4, 16, 64, 128]$;
 $M - PSK = [2, 4, 16]$. Avec M désigne l'ordre de modulation.
- Configuration antennaire utilisée : $N_T \times N_R = 2 \times 8, 4 \times 8, 8 \times 8$.
- Nombre de simulations = 3500 (500 pour chaque ordre de modulation).
- Nombre de symbole = 1024.

IV.2.3 Performances obtenues avec la modulation M-QAM

- **Évaluation du BER**

Les courbes suivantes illustrent une comparaison du BER obtenu avec différents ordres de modulation QAM en fonction du rapport signal sur bruit SNR en utilisant un égalisateur MMSE. D'après les résultats, nous pouvons noter que :

- Pour une même configuration antennaire : En augmentant l'ordre de modulation c.-à-d. la taille de la constellation, le taux de bits erronés augmente. Donc les performances se dégradent. Cela s'explique par le fait que l'augmentation de M réduit la distance entre symboles adjacents sur la constellation.
- Pour différentes configurations antennaires avec M constant : En augmentant le nombre d'antennes en émission et en réception, le BER diminue. Nous pouvons clairement conclure que la diversité spatiale est primordiale pour améliorer la qualité et la robustesse de transmission.

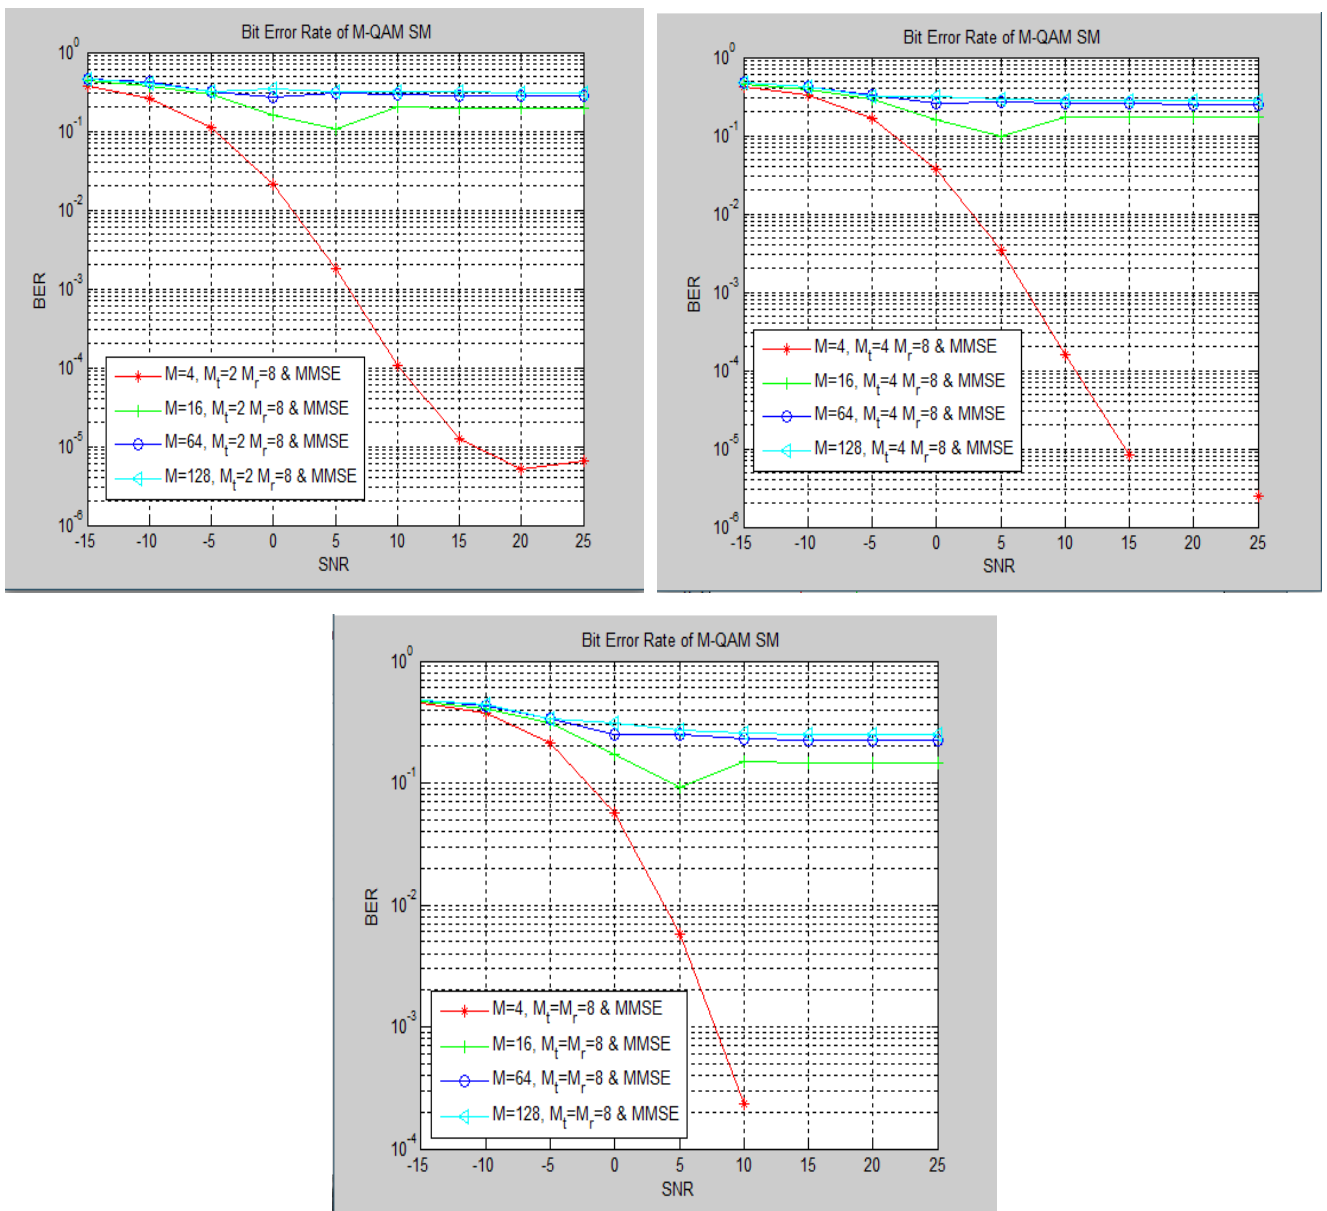


Figure IV.1 : Comparaison BER pour différentes configurations antennaires.

• Évaluation de la capacité

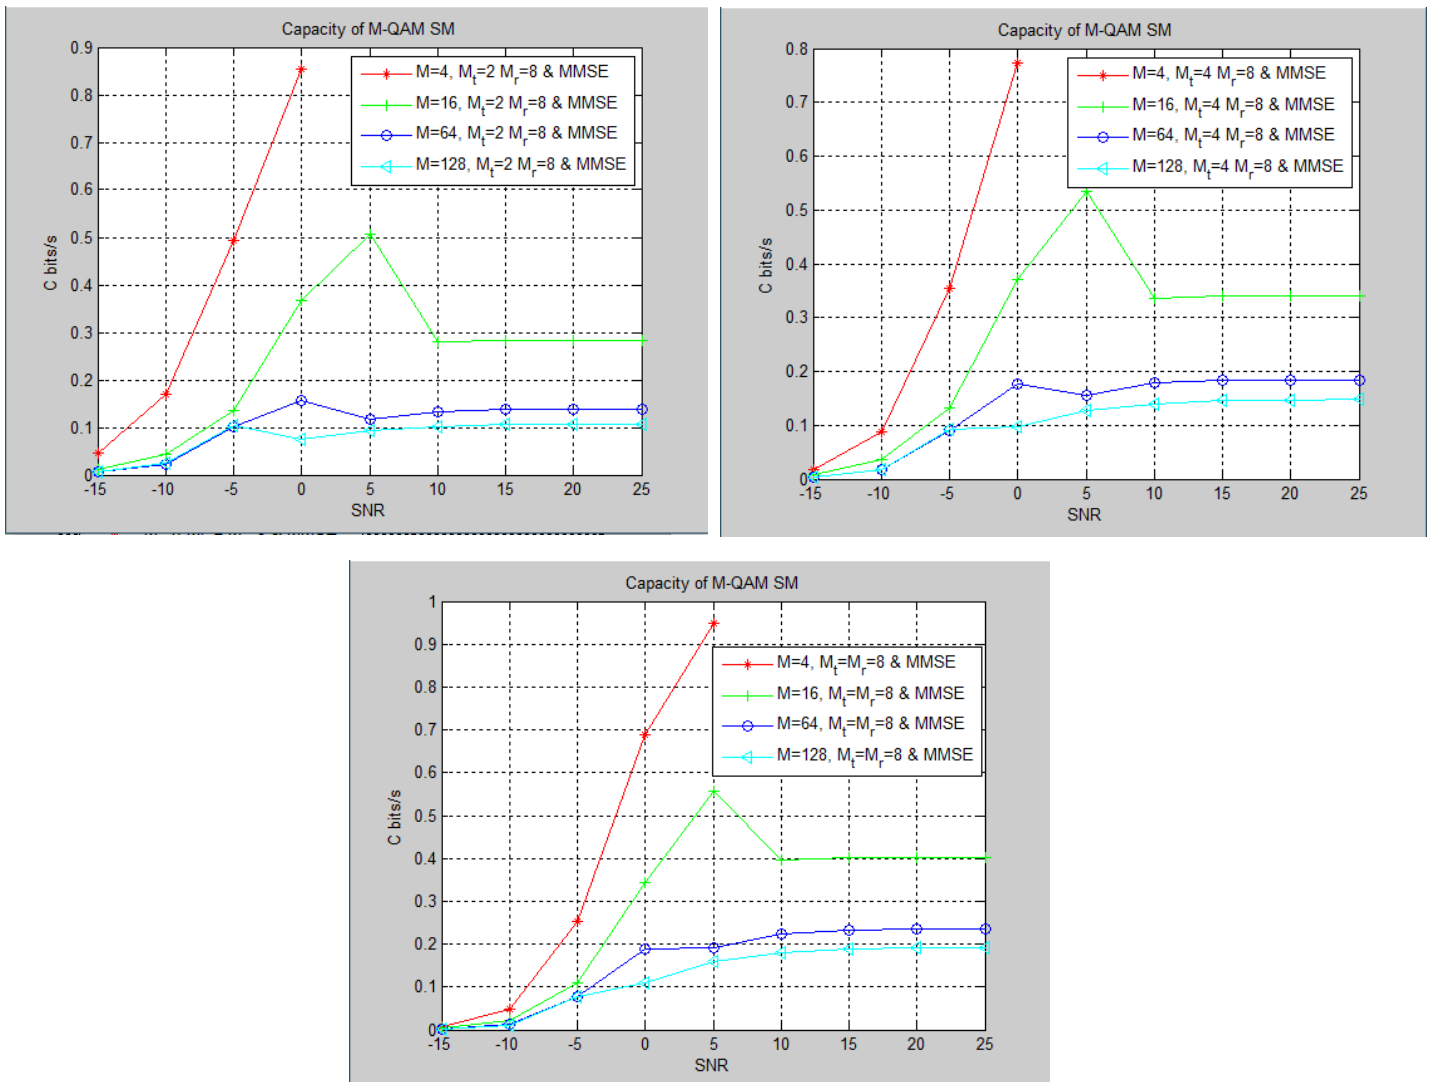


Figure IV.2 : Comparaison de la capacité pour différentes configurations antennaires.

On constate à partir des graphes que :

- Pour une même configuration : La capacité décroît avec le nombre d'états. Cela s'explique par le fait que l'augmentation de l'ordre de modulation permet d'occuper une bande passante de plus en plus réduite.
- Pour différentes configurations : La capacité croît linéairement avec le nombre d'antennes. Nous constatons donc que les performances se dégradent quand le nombre d'antenne est réduit.

• Évaluation de l'efficacité spectrale

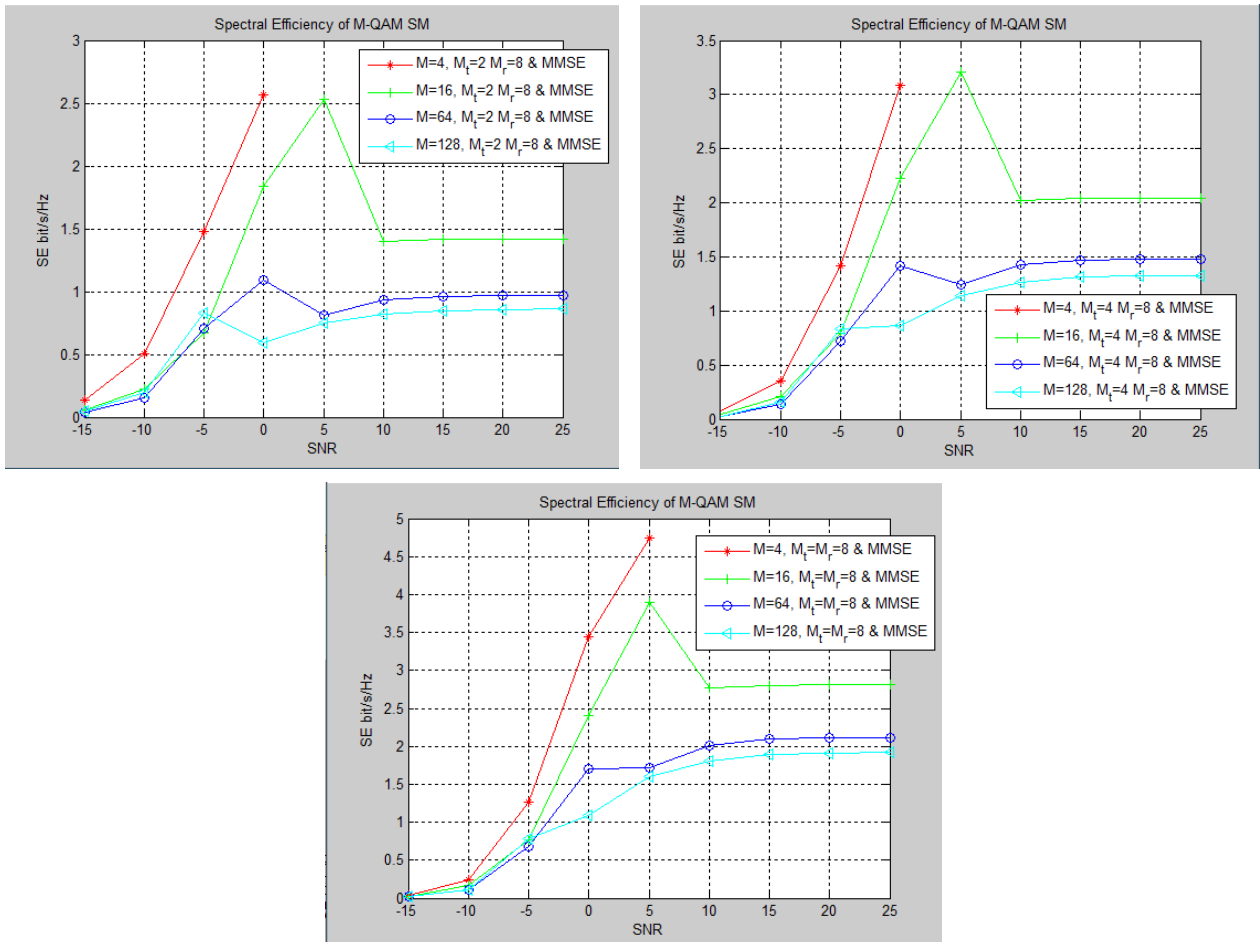


Figure IV.3 : Comparaison de l'efficacité spectrale pour différentes configurations antennaires.

Selon les résultats obtenus, nous constatons que

- En augmentant le nombre de constellation, l'efficacité spectrale augmente, ce qui signifie qu'en augmentant l'ordre de modulation, le débit du système augmente ce qui assure l'évolution de l'efficacité spectrale.
- L'efficacité spectrale croît proportionnellement avec le nombre d'antenne émettrices/réceptrice et peut atteindre des valeurs élevées.

IV.2.4 Performances obtenues avec la modulation M-PSK

• Évaluation du BER

Il ressort clairement des figures suivantes, qu'en augmentant la taille de la constellation (l'ordre de modulation), le BER augmente et les performances se dégradent. On remarque aussi qu'en augmentant le nombre d'antennes, le BER diminue. Nous pouvons clairement conclure que la diversité spatiale est primordiale pour améliorer la qualité et la robustesse de transmission.




Figure IV.4 : Comparaison du BER obtenu avec différents ordres de modulation de PSK.

• **Évaluation de la capacité**

En analysant les résultats présentés, on voit que la capacité décroît avec le nombre d'états. Cela s'explique par le fait que l'augmentation de l'ordre de modulation permet d'occuper une bande passante BW de plus en plus faible, ce qui affaiblit la capacité du système.




Figure IV.5 Comparaison des capacités obtenue avec une modulation de PSK.

• **Évaluation de l'efficacité spectrale**

On constate à partir des graphes ci-dessous que l'efficacité spectrale évolue lorsque le nombre d'états augmente, ce qui signifie que l'augmentation de nombre d'états permet, d'occuper une bande de fréquence de plus en plus faible, mais la robustesse au bruit diminue dans les mêmes proportions.




Figure IV.6 : Comparaison de l'efficacité spectrale obtenue avec une modulation de PSK.

IV.3 Évaluation des performances des classifieurs

Cette seconde partie de nos simulations concerne la classification automatique de signaux selon leurs types de modulations (AMC) grâce à un classifieur à base d'un réseau de neurones.

L'évaluation des performances d'un classifieur est une étape critique pour le choix, la comparaison et la validation des algorithmes de classification. En effet, même si le taux de bonne classification ou encore l'erreur globale de classification fournissent une information importante, ils sont rarement suffisants pour caractériser précisément la machine de classification. C'est pour ça que diverses métriques sont utilisées pour renforcer le jugement sur la qualité du classifieur.

IV.3.1 Métriques des performances utilisées

La lisibilité des résultats de la classification est cruciale pour l'amélioration des performances des classifieurs. Diverses mesures servent à renforcer le jugement sur la qualité de la classification.

- **Matrice de confusion**

La matrice de confusion dans un classifieur à réseau de neurones artificiels est une matrice de M lignes et N colonnes qui mesure la qualité de ce dernier. Chaque ligne correspond à une classe prédite, tandis que chaque colonne correspond à une classe désirée. L'atout majeur de cette matrice est qu'elle montre rapidement si un système de classification parvient à classer correctement les données. [20]

Divers indicateurs de performance sont extraits à partir la matrice de confusion, résumés dans le tableau ci-dessous [20] :

<i>Indicateurs de performance</i>	<i>Équation</i>
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 : Indicateurs de performance d'un classifieur.

En plus de ces dernières, une mesure globale des performances du classifieur peut être calculée grâce à la métrique F-score qui est définie comme suit :

$$f = 2 \frac{\Psi\delta}{\Psi+\delta} \quad (\text{IV.3})$$

- **La courbe ROC :**

Les courbes ROC inventées durant la seconde guerre mondiale pour la mise au point de moyens efficaces de détection des avions ennemis et la séparation entre les signaux radars et le bruit. Elles mesurent les performances d'un classifieur en divisant les éléments à classifier en plusieurs groupes différents en fonction d'une ou plusieurs caractéristiques. La courbe ROC se définit par une représentation du taux des vrais positifs en fonction du taux des faux positifs. Cette représentation met en évidence un autre indicateur performance pertinent, appelé l'aire sous la courbe (AUC) [39].




Figure IV.7 : Interprétation de la courbe ROC.

IV.3.2 Méthodologie de simulation

Cette section traite des performances d'un classifieur ANN que nous avons construit par apprentissage pour l'identification des types de modulation avec différentes configurations antennaires. La première phase consiste à extraire les données caractérisant chaque type de modulation, les statistiques d'ordre supérieur (HOS). Ces dernières seront utilisées dans une seconde phase comme entrées pour notre classifieur.

Pour assurer une bonne construction de notre classifieur, les données extraites sont réparties en trois ensembles, un grand ensemble pour l'entraînement (70%), un ensemble plus réduit pour la phase de test (15%) et le reste pour la phase de validation du classifieur (15%).

Le schéma ci-dessous résume les différentes étapes citées précédemment :

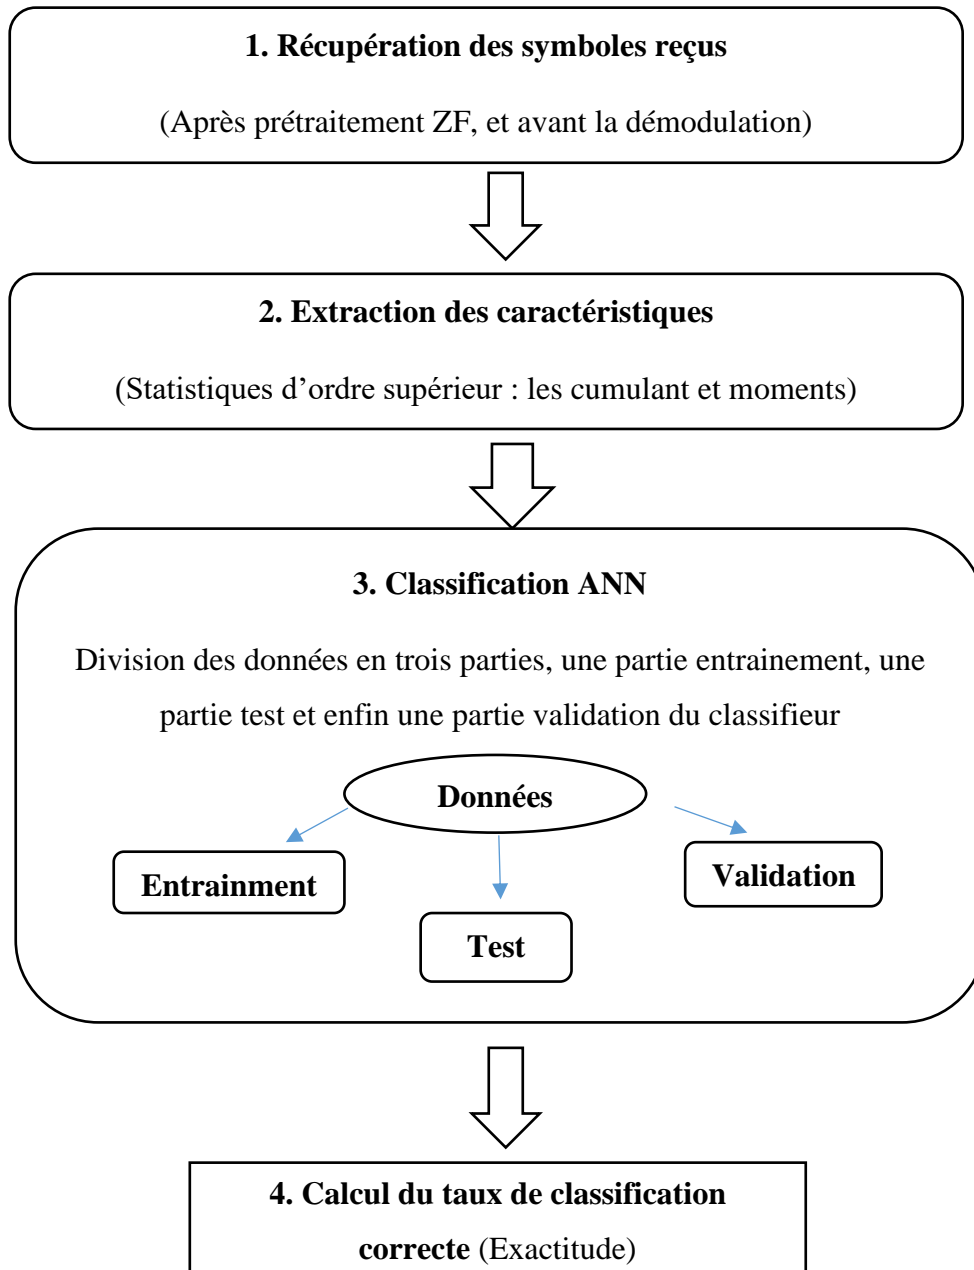


Figure IV.8 : Schéma récapitulatif des différents processus.

Nous avons restreint nos simulations à quatre types de modulation {BPSK, QPSK, 64QAM, 128QAM} avec 1000 simulations pour chaque type de modulation (soit 4000 simulations au total) et pour des SNR= {-15, 20, 30}. L'algorithme de classification que nous avons étudié est celui présenté précédemment, à savoir le classifieur à base de réseaux de neurones artificiels. Nous précisons que tous ces classifieurs sont soumis aux mêmes conditions d'apprentissage et de test.

Nous soulignons que nous avons considéré un égaliseur ZF pour les diverses configurations antennaires utilisées. L'évaluation des performances du classifieur est faite en calculant son taux de classification correcte (Accuracy) en fonction de chaque SNR et en déterminant les autres métriques citées précédemment.

IV.3.3 Réseau de neurones utilisé

Pour nos simulations, nous avons utilisé un réseau ANN composé de :

- Une couche d'entrée à 06 entrées ;
- Deux couches cachées avec fonction sigmoïde comme fonction de transfert : la première est composée de 13 neurones, la deuxième de 07 neurones ;
- Une couche de sortie avec 04 sorties.




Figure IV.9 : Réseau de neurones utilisé.

IV.3.4 Évaluation du taux de classification correcte

Pour commencer, nous soulignons que nos configurations sont indicées sous le type $HOS_ZF_n_T X n_R$ où **HOS** définit les données extraites, **ZF** indique le type de détection choisi, et $n_T X n_R$ la configuration antennaire utilisée. L'évaluation des classificateurs est basée sur taux de classification correcte (Accuracy) en fonction de SNR (dB).

D'après les résultats illustrés sur la figure suivante, il ressort que les performances de notre classifieur sont très satisfaisantes pour toutes les configurations avec des valeurs adéquates de rapport SNR. Par contre pour des valeurs faibles de celui-ci, les taux de classification correcte obtenus sont beaucoup moins satisfaisants. Nous pensons que cette limitation est due à la qualité du détecteur utilisées au niveau du récepteur.

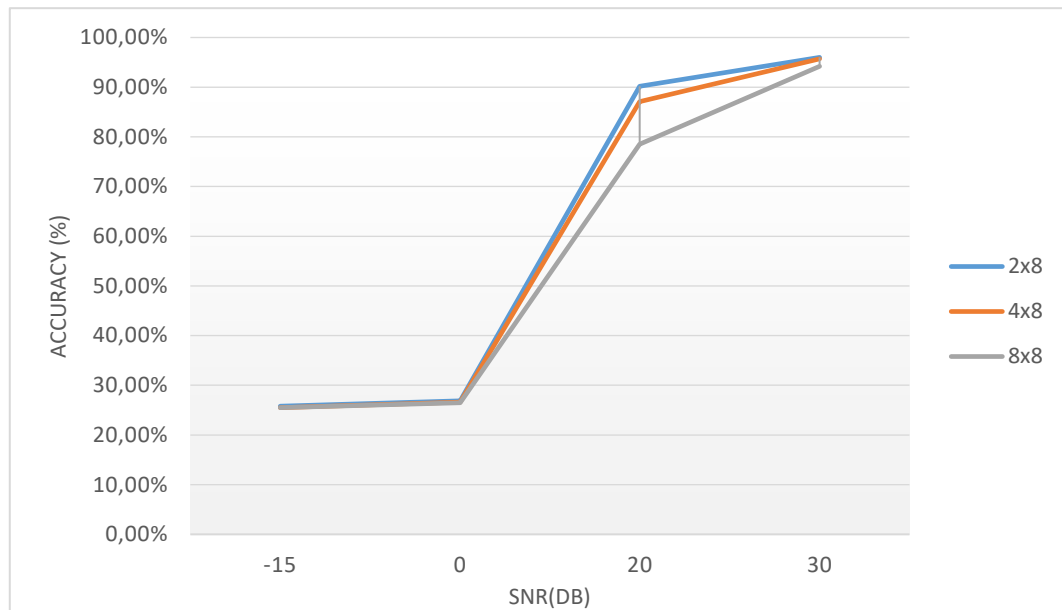


Figure IV.10 : l'Accuracy des configurations antennaires pour les différents SNR.

IV.3.5 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 classifieurs obtenues en variant le rapport SNR= [-15, 0, 20, 30] pour trois types de configuration 2x8, 4x8 et 8x8. Les résultats obtenus sont synthétisés dans les tableaux suivants.

- Matrice de confusion pour la Configuration 2x8 :

		Classes réelles				
		BPSK	QPSK	64QAM	128QAM	
SNR=-15	Classes prédites	BPSK	59(5.9%)	907(90.7%)	10(1.0%)	24(2.4%)
		QPSK	40(4%)	943(94.3%)	3(0.3%)	14(1.4%)
		64QAM	36(3.6%)	939(93.9%)	9(0.9%)	16(1.6%)
		128QAM	36(3.6%)	933(93.3%)	12(1.2%)	19(1.9%)
SNR=20	Classes prédites	BPSK	937(93.7%)	61(6.1%)	1(0.1%)	1(0.1%)
		QPSK	34(3.4%)	915(91.5%)	32(3.2%)	19(1.9%)
		64QAM	47(4.7%)	48(4.8%)	852(85.2%)	53(5.3%)
		128QAM	60(6%)	19(1.9%)	16(1.6%)	905(90.5%)
SNR=30	Classes Prédites	BPSK	994(99.4%)	4(0.4%)	2(0.2%)	0(0%)
		QPSK	31(3.1%)	954(95.4%)	13(1.3%)	2(0.2%)
		64QAM	31(3.1%)	11(1.1%)	940(94%)	18(1.8%)
		128QAM	20(2%)	17(1.7%)	9(0.9%)	954(95.4%)

Tableau IV.2 : Matrices de confusion pour la configuration 2x8.

- Matrice de confusion pour la Configuration 4x8

		Classes réelles				
		BPSK	QPSK	64QAM	128QAM	
		SNR=-15	Classes prédites	BPSK	951(95.1%)	11(1.1%)
QPSK	936(93.6%)			20(2%)	31(3.1%)	13(1.3%)
64QAM	939(93.9%)			11(1.1%)	33(3.3%)	17(1.7%)
128QAM	934(93.4%)			16(1.6%)	33(3.3%)	17(1.7%)
		Classes réelles				
		BPSK	QPSK	64QAM	128QAM	
		SNR=20	Classes prédites	BPSK	939(93.9%)	15(1.5%)
QPSK	41(4.1%)			831(83.1%)	95(9.5%)	33(3.3%)
64QAM	72(7.2%)			18(1.8%)	828(82.8%)	82(8.2%)
128QAM	56(5.6%)			7(0.7%)	51(5.1%)	886(88.6%)
		Classes réelles				
		BPSK	QPSK	64QAM	128QAM	
		SNR=30	Classes prédites	BPSK	972(97.2%)	26(2.6%)
QPSK	11(1.1%)			960(96%)	20(2%)	9(0.9%)
64QAM	18(1.8%)			23(2.3%)	943(94.3%)	16(1.6%)
128QAM	22(2.2%)			20(2%)	4(0.4%)	954(95.4%)

Tableau IV.3 : Matrices de confusion pour la configuration 4x8.

- Matrice de confusion pour la Configuration 8x8

SNR=-15			Classes réelles			
			BPSK	QPSK	64QAM	128QAM
	Classes prédites	BPSK	141(14.1%)	737(73.7%)	57(5.7%)	65(6.5%)
		QPSK	134(13.4%)	753(75.3%)	44(4.4%)	69(6.9%)
		64QAM	150(15.0%)	719(71.9%)	76(7.6%)	55(5.5%)
128QAM		128(12.8%)	746(74.6%)	63(6.3%)	63(6.3%)	
SNR=20			Classes réelles			
			BPSK	QPSK	64QAM	128QAM
	Classes prédites	BPSK	898(89.8%)	85(8.5%)	10(1.0%)	7(0.7%)
		QPSK	84(8.4%)	797(79.7%)	88(8.8%)	31(3.1%)
		64QAM	105(10.5%)	103(10.3%)	685(68.5%)	107(10.7%)
128QAM		89(8.9%)	78(7.8%)	75(7.5%)	758(75.8%)	
SNR=30			Classes réelles			
			BPSK	QPSK	64QAM	128QAM
	Classes prédites	BPSK	960(96%)	35(3.5%)	1(0.1%)	4(0.4%)
		QPSK	17(1.7%)	951(95.1%)	10(1.0%)	22(2.2%)
		64QAM	28(2.8%)	25(2.5%)	909(90.9%)	38(3.8%)
128QAM		28(2.8%)	21(2.1%)	3(0.3%)	948(94.8%)	

Tableau IV.4 : Matrices de confusion pour la configuration 8x8.

D'après ces trois matrices de confusion obtenues pour les configurations antennaires considérées, nous pouvons déduire la précision du classifieur pour chaque cas comme représenté dans le tableau suivant :

		Configuration antennaire		
		2x8	4x8	8x8
SNR	-15	25.8%	25.5%	25.8%
	20	90.2%	87.1%	78.5%
	30	96%	95.7%	94.2%

Tableau IV.5 : Tableau récapitulatif des différentes simulations.

D'après le tableau ci-dessus, il ressort que les résultats obtenus pour les quatre types de modulations sont très prometteurs, et que les meilleures performances sont pour une configuration antennaire 8x8. Nous pouvons déduire que la diversité spatiale joue un rôle crucial pour améliorer les performances.

IV.3.6 Détermination des courbe ROC

Dans cette étude, nous avons mis en évidence un autre indicateur d'évaluation pertinent déployé pour mesurer la performance d'un classifieur.

- **Courbes ROC pour SNR -15**




Figure IV.11 : Configuration 2x8.




Figure IV.12 : Configuration 4x8.




Figure IV.13 : Configuration 8x8.

D'après les figures précédentes nous pouvons constater que pour un SNR faible, une qualité médiocre du classifieur malgré la diversité spatiale. Dans ce cas le classifieur est un classifieur aléatoire.

- **Courbes ROC pour SNR 0**




Figure IV.14 : Configuration 2x8.




Figure IV.15 : Configuration 4x8.




Figure IV.16 : Configuration 2x8.

Ces figures confirment le résultat précédent à savoir que pour des rapports SNR faibles (ici SNR=0db) le classifieur est un classifieur aléatoire, donc non performant.

- Courbes ROC pour SNR 20

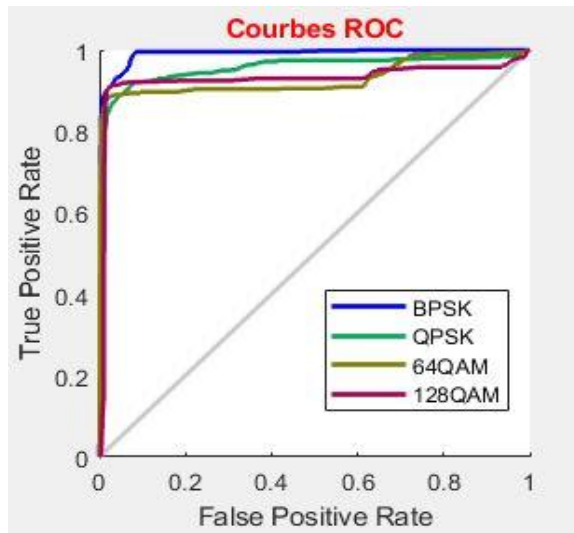


Figure IV.17 : Configuration 2x8.




Figure IV.18 : Configuration 4x8.

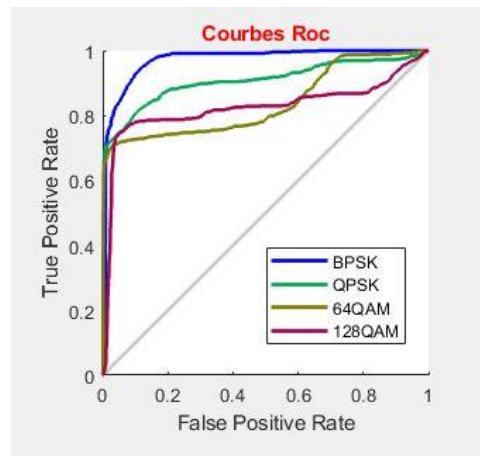


Figure IV.19: Configuration 8x8.

D'après ces résultats, il ressort que le classifieur est plus performant et que sa précision est meilleure que pour des SNR faibles pour toutes les configurations et toutes les modulations. L'aire sous la courbe (AUC) croit de façon importante pour tous les cas traités.

- **Courbes ROC pour SNR 30**

Les résultats suivants confirment la même tendance que précédemment, à savoir que le classifieur est très performant pour un rapport signal bruit élevé pour toutes les configurations antennaires considérées et toutes les modulations utilisées.




Figure IV.20 : Configuration 2x8.




Figure IV.21 : Configuration 4x8.




Figure IV.22 : Configuration 8x8.

IV.4 Conclusion

Dans ce présent chapitre, nous avons analysé et évalué les performances de systèmes MIMO à modulation spatiale en fonction de plusieurs paramètres tels que l'ordre de modulation ainsi que le nombre d'antenne émettrices/réceptrices. Nous avons aussi présenté les métriques d'évaluations des performances des classifieurs dans le but de tester leurs robustesses. Par la suite nous avons effectué diverses simulations dans le but de reconnaître les types de modulation.

Les résultats des simulations ont révélé que, pour des rapports SNR de grande ampleur, le classifieur ANN jouit d'une grande précision, et atteint des performances très élevées, confirmant ainsi sa capacité dans la discrimination entre les différents types de modulation.

Conclusion générale

La reconnaissance automatique de type de modulation consiste à identifier au niveau du récepteur d'une chaîne de transmission, la constellation à laquelle appartient les symboles des messages transmis. Cette reconnaissance est nécessaire dans de nombreux scénarios de communications qu'ils soient coopératifs et non coopératifs. Les réseaux de neurones artificiels RNA sont considérés comme un moyen efficace permettant une meilleure classification.

Ce mémoire nous a permis d'explorer le domaine de l'apprentissage machine et d'évaluer le potentiel de l'utilisation des réseaux neurones artificiels RNA dans le cas de multiclassés. Notre objectif est d'utiliser des RNA et d'étudier leurs performances pour la reconnaissance automatique de types de modulation.

Le premier volet du travail, nous avons commencé par la présentation du principe de la radio cognitive en passant par ses fonctionnalités, ses composants. Puis, nous avons réalisé une étude détaillée sur les techniques MIMO et la modulation spatiale. Pour ensuite mettre l'accent sur la méthode de classification et approfondir dans les réseaux de neurones RNA.

Le deuxième volet du travail constitue notre contribution, en utilisant un réseau de neurones, composé d'une couche d'entrée, 2 couches cachées et une couche de sortie, pour la détection automatique de type de modulation basée sur l'extraction de caractéristique. D'après les résultats obtenus à travers ces expérimentations, nous pouvons noter que :

- La phase d'extraction de données utilisées pour la classification est cruciale pour faciliter la discrimination entre les divers types de modulations ;
- Les RNA ont permis des taux de bonne classification qui atteignent jusqu'à 96 %, ce qui montre que les RNA sont très puissants pour la tâche considérée.

Sur le plan pédagogique, nous avons saisi cette opportunité pour approfondir nos connaissances acquises pendant le cursus universitaire et ce, en télécommunication plus précisément en radio cognitive, systèmes MIMO et en classification de données.

Finalement, nous espérons que notre travail puisse servir pour de futures études, notamment pour :

- Proposer des techniques robustes pour la reconnaissance automatique d'autres paramètres de communication tels que le type de codage, le réseau d'antennes utilisé etc...
- Améliorer les performances du classifieur RNA même pour les faibles SNR.

Références Bibliographiques

- [1] Soulé de Castro, Rodrigo. *Amélioration des performances et de la capacité dans les systèmes d'accès dynamique au spectre*. Diss. Paris, Télécom ParisTech, 2011.
- [2] Kokar, Yvan. *Études de la mise en oeuvre matérielle d'une transmission sans fil combinant retournement temporel et OFDM*. Diss. INSA de Rennes, 2018.
- [3] BALLESTEROS, Marc. Les technologies sans fil. EIVD, Juin, 2002.
- [4] Nicolas, M. Radio logicielle : analyse d'architectures matérielles et outils informatiques, 2011.
- [5] A. Metref. "Contribution à l'étude du problème de synchronisation de porteuse dans le contexte de la Radio Intelligente ", Novembre 2010.
- [6] B. Benmammar, A. Amraoui. 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, pp 233, 2020.
- [7] B. Benmammar, A. Amraoui., Radio Resource Allocation and Dynamic Spectrum Access. Wiley-ISTE, 2012.
- [8] Ngom, Insa, and Louis Diouf. "LA RADIO COGNITIVE", Master Professionnel Télécommunications, 2007/2008.
- [9] E. Hossain, D. Niyan, Zhu Han. "Dynamic Spectrum Access and management in cognitive radio networks", Cambridge University Press, 2009.
- [10] R.Kamath. « Spectrum sensing in cognitive radio networks », International Conference on Control, Communication and Computing, 2010.
- [11] Mahmood A.Abdulsattar and Zahir A.Hussain. « Energy Detection for spectrum sensing in cognitive radio : Survey », in International Journal of Computer Networks & Communications (IJCNC) vol 4, September 2012.
- [12] Abdessamad, El Rharras & Rachid, Saadane & Wahbi, Mohammed & Hamdoun, A. « Signal Detection and Automatic Modulation Classification Based Spectrum Sensing Using PCA-ANN with Real Word Signals », Applied Mathematical Sciences. 8. 7959-7977. 10.12988/ams.2014.49736, 2014.
- [13] Millet, J. BIG DATA : nouvelles partitions de l'information : Actes du séminaire IST Inria, De Boeck Supérieur, octobre 2014.
- [14] N. Geisinger. « Classification of digital modulation schemes using linear and nonlinear classifiers, » Master's thesis, Naval Postgraduate School, California, 2010.
- [15] Gide, A. Chapitre 3 L'apprentissage automatique en télédétection. rat,pp 63, 2017.
- [16] Touzet, C. les réseaux de neurones artificiels, introduction au connexionnisme. Ec2, 1992.

- [17] ATIAM, R. D. S. M., & ROSKAM, F. Une Approche généralisée avec EDS,2006.
- [18] M. BENYAROU, F. T. BENDIMERAD, F. DEBBAT. « Multi-User Detection for Multibeam-MIMO-Multi-Carrier-CDMA systems with MMSE adaptive algorithm » International Journal of Computer Science Issues IJCSI,Volume 10, 2013.
- [19] Tourin, A., de Rosny, J., Derode, A., Lerosey, G., & Fink, M. Télécommunications par retournement temporel dans les environnements complexe.
- [20] Hakim TAYAKOUT. « Détection itérative par Turbo codage combinant différentes techniques à base de systèmes MIMO », Thèse de doctorat en Electronique, Ecole Nationale Polytechnique, 2019.
- [21] Ammar, M. A. Z. R. I. Etude d'un modèle de canal MIMO.
- [22] Ludovic COLLIN « Optimisation de systèmes multi antennes basée sur la distance minimale », l'Université de Bretagne Occidentale, 17 décembre 2002.
- [23] Pierre GRUYER, Simon PAILLARD. « Modélisation d'un modulateur et démodulateur OFDM », Université de Bretagne ,12 décembre 2005.
- [24] GOLDEN, G. D., FOSCHINI, G. J., WOLNIANSKI, P. W., et al. V-BLAST : A high capacity space-time architecture for the rich-scattering wireless Channel. Bell Laboratoires, IsarT-98, vol. 150, 1998.
- [25] R. Mesleh, H. Haas, Y. Lee et S. Yun. « Évitemment des interférences entre canaux dans la transmission MIMO en exploitant l'information spatiale », Proc. IEEE 16th Int. Symp. Pers. Radio mobile intérieure Commun. vol. 1, pp. 141-145, sept 2005.
- [26] S. U. Hwang, S. Jeon, S. Lee, and J. Seo. "Soft-output ML detector for spatial modulation OFDM systems," IEICE Electron. Exp., vol. 6, no. 19, pp. 1426–1431, Sep 2009.
- [27] Zayani, R. Pré-distorsion adaptative des non-linéarités HPA dans un système OFDM à l'aide des réseaux de neurones (Doctoral dissertation, ENIT), 2009.
- [28] C. Touzet. « Les réseaux de neurone artificiels », Cours, Université de Provence (Aix- Marseille I), juillet 1992.
- [29] H. Abdi. « Les Réseaux de neurones », édition presses universitaires de Grenoble, 1994.
- [30] P.K. Simpson. «Artificial Neural Systems», Pergmon Press Elmsford, New York,1989.
- [31] G. Dreyfur. « Réseaux de neurones : Méthodologie et application », édition Eyrolles, 2004.
- [32] A. Blum. « Neural Networks in C ++ », Wiley & Sons Edit, New York, 1992.
- [33] A.K. Jain, J. Mao et K.M Muhiuddin, Artificial Neural Networks : A tutorial, IEEE, pp.31-44, Mars 1996.

- [34] Ammar Assoum, Etude de la tolérance aux aléas logiques des réseaux de neurones artificiels. Thèse doctorat ,1997.
- [35] Rachid LADJADJ. Les réseaux de neurones. Site WEB, 2002/2003.
- [36] Touzet, C. Contribution à l'étude et au développement de modèles connexionnistes séquentiels de l'apprentissage. Thèse de doctorat. Université de Montpellier II, 1990.
- [37] Marc Parizeau. Le perceptron multicouche et son algorithme de rétropropagation des erreurs. Département de génie électrique et de génie informatique. Université Laval, 10 septembre 2004.
- [38] Belhadj, B. Systèmes neuromorphiques temps réel : contribution à l'intégration de réseaux de neurones biologiquement réalistes avec fonctions de plasticité. Thèse de doctorat. Université Sciences et Technologies-Bordeaux I), 2010.
- [39] T. O'Shea and J. Hoydis. An introduction to deep learning for the physical layer, IEEE Trans. Cognit. Commun. Netw., vol. 3, no. 4, pp. 563575, Dec. 2017.

Résumé

Le travail abordé dans ce mémoire concerne la diversité coopérative avec laquelle nous avons combiné deux techniques très utilisées dans le domaine des communications sans fil à savoir : le système MIMO à modulation spatiale (SM-MIMO) et la radio cognitive, et ce afin d'améliorer les performances et la qualité des transmissions. La reconnaissance automatique de type de modulation (AMC) est parmi les fonction importante de la radio cognitive (RC). Cette dernière permet une meilleure gestion du spectre fréquentiel. Ce projet porte sur l'étude des performances d'un système de classification automatique de type de modulation à base de réseau de neurones. Les résultats de simulations obtenus ont démontré de meilleures performances des solutions proposées et une grande robustesse face aux erreurs d'estimation des canaux.

Mots clés

Diversité coopérative, système MIMO, SM-MIMO, radio intelligente, La reconnaissance automatique de type de modulation, Radio Cognitive, Réseau de neurones.

Abstract

The work addressed in this thesis concerns the cooperative diversity with which we have combined two techniques widely used in the field of wireless communications: the space modulation MIMO system (SM-MIMO) and cognitive radio, in order to improve the performance and quality of transmissions. The automatic recognition of modulation type (AMC) is one of the important functions of cognitive radio (CR). The cognitive radio allows a better management of the frequency spectrum. This project focuses on the study of the performance of an automatic modulation type classification system with neural network. The simulation results obtained have shown better performance of the proposed solutions and a high robustness to channel estimation errors.

Keywords

Cooperative diversity, MIMO system, space modulation MIMO system, intelligent radio, Automatic Modulation Type Recognition, Cognitive Radio, Neural Network.