



**Université de Batna 2 – Mostefa Ben Boulaïd**  
**Faculté de Technologie**  
**Département d'Electronique**



**Thèse**

Préparée au sein du Laboratoire d'Automatique Avancée et d'Analyse des Systèmes

Présentée pour l'obtention du titre de :  
**Docteur en Sciences en Electronique**  
**Option : Micro-ondes et Télécommunication**

Sous le Thème :

**Contribution au développement d'algorithmes  
d'optimisation dans les réseaux mobiles**

Présentée par :

**BOUGUERRA Fateh**

**Devant le jury composé de :**

M. BENZID Redha	Prof.	Université de Batna 2	Président
M. SAIDI Lamir	Prof.	Université de Batna 2	Rapporteur
M. MESSAI Abderraouf	Prof.	Université de Constantine 1	Examineur
M. ZIAR Toufik	MCA.	Université de Tébessa	Examineur

**Décembre 2018**

***Contribution au développement  
d'algorithmes d'optimisation  
dans les réseaux mobiles***



*Special Thanks to Mr. SAIDI Lamir for his efforts and assistance; driving me to the right way and his patient on my errors, he was like a missed colleague.*

*I would to thank Mr. BENZID Redha to have agreed to chair the Jury of this dissertation.*

*Also, I address my cordial thanks to Mr. MESSAI Abderraouf and Mr. ZIAR Toufik for the honour they made me to judge this modest work.*

*To my family, specially my mother.*

## Résumé

La modulation à ordre supérieur (HOM) représente un défi majeur pour l'augmentation de l'efficacité du spectre dans les systèmes de communication 4G et 5G à venir. Dans cette thèse, deux techniques d'égalisation adaptative non-linéaire basées sur le MLP (Multi-layer Perceptron) et la RBF (Radial Basis Function) sont conçues et appliquées sur HOM pour optimiser ses performances malgré sa grande sensibilité au bruit et aux distorsions du canal. Les architectures d'égaliseurs adaptatifs du réseau neuronal artificiel (ANN) et les méthodes d'apprentissage sont simplifiées pour éviter une grande complexité et assurer une certaine rapidité dans la prise de décision dans la reconstitution des symboles. Ils seront comparés avec les filtres adaptatifs populaires ; Moyenne minimale carrée (LMS) et moindres carrés récurrents (RLS) en termes de taux d'erreur binaire (BER) et d'erreur quadratique minimale (MSE) avec les modulations d'amplitude en quadrature (QAM) 16, 64, 128, 256, 512 et 1024. Ce travail montrera l'efficacité de l'égaliseur MLP dans la plupart des cas sur son homologue RBF et les égaliseurs linéaires traditionnels.

## **Abstract**

High Order Modulation (HOM) presents a key challenge in increasing specter efficiency in 4G and upcoming 5G communication systems. In this dissertation, two non-linear adaptive equalizer techniques based on Multilayer Perceptron (MLP) and Radial Basis Function (RBF) are designed and applied on HOM to optimize its performances despite its high sensitivity to noise and channel distortions. The Artificial Neural Network (ANN) adaptive equalizers architectures and learning methods are simplified to avoid much more complexity and ensure some speed in symbol decision making. They will be compared with the popular adaptive filters; Least Mean Square (LMS), and Recursive Least Squares (RLS) in terms of Bit Error Rate (BER) and Minimum Square Error (MSE) with 16, 64, 128, 256, 512 and 1024 Quadrature Amplitude Modulation (QAM). This work will show the efficiency of MLP equalizer in most cases over RBF and traditional linear equalizers.

## ملخص

يمثل تضمين الترتيب العالي (HOM) تحديًا رئيسيًا في زيادة فاعلية طيف الجيل الرابع وأنظمة اتصالات الجيل الخامس القادمة. في هذه الأطروحة، تم تصميم وتطبيق اثنين من تقنيات التعادل التكيفية غير الخطية على أساس Perceptron متعدد الطبقات (MLP) ووظيفة الأساس الأحادي (RBF) على HOM لتحسين أدائها على الرغم من حساسيتها العالية للضجيج وتشويش القناة. لقد تم تبسيط هندسة معادلات التكيف العصبية الاصطناعية (ANN) وأساليب التعلم لتفادي الكثير من التعقيد وضمان بعض السرعة في صنع قرار إعادة بناء الرموز. سيتم مقارنتها مع المرشحات التكيفية الكثيرة الاستعمال؛ المتوسط المربع الأصغر (LMS) والمربعات التكرارية الصغرى (RLS) من حيث معدل خطأ البت (BER) والحد الأدنى للخطأ المربع (MSE) مع 16، 64، 128، 256، 512 و 1024 تعديل التحجيم التربيعي (QAM). من خلال ذلك، سيظهر هذا العمل كفاءة التعادل MLP في معظم الحالات على RBF والمعادلات الخطية التقليدية.



# Sommaire

ACRONYMES & ABRÉVIATIONS.....	XII
-------------------------------	-----

LISTE DES FIGURES .....	XVI
-------------------------	-----

INTRODUCTION GÉNÉRALE.....	18
----------------------------	----

<b>CHAPITRE I : LTE-ADVANCED ET SA COUCHE PHYSIQUE.....</b>	<b>22</b>
---	-----------

I.1. INTRODUCTION.....	22
I.2. LTE-A .....	22
I.2.1. <i>Avantages de la LTE-A</i> .....	23
I.2.2. <i>Techniques d'accès</i> .....	23
I.2.3. <i>Agrégation de porteuses (Carrier Aggregation)</i> .....	24
I.2.4. <i>Scénarios de déploiement</i> .....	27
I.2.5. <i>MIMO</i> .....	29
I.3. OFDM.....	32
I.3.1. <i>Préfixe cyclique</i> .....	34
I.3.2. <i>Génération de la porteuse OFDM</i> .....	35
I.3.3. <i>Egaliseur OFDM &amp; multi-trajets</i> .....	35
I.3.4. <i>Accès multiple (OFDMA)</i> .....	36
I.3.5. <i>Avantages &amp; désavantages</i> .....	39
I.4. CONCLUSION .....	40

<b>CHAPITRE II : MODULATION À ORDRE SUPÉRIEUR &amp; ÉGALISATION DU CANAL. 42</b>
--

II.1. INTRODUCTION.....	42
II.2. TYPES DE MODULATIONS.....	43
II.2.1. <i>Binary Phase Shift Keyed (BPSK)</i> .....	43
II.2.2. <i>Gaussian Minimum Phase-shift Keying (GMSK)</i> .....	43
II.2.3. <i>Octagonal Phase-shift Keying (8-PSK)</i> .....	43
II.2.4. <i>Quarter Phase-Shift Keying (QPSK)</i> .....	43
II.2.5. <i>Quadrature Amplitude Modulation (M-QAM)</i> .....	44
II.3. HOM .....	44
II.4. ÉGALISATION.....	45
II.4.1. <i>Egalisation adaptative</i> .....	46
II.4.1.1. <i>Filtrage numérique</i> .....	47

II.4.1.2.	Types d'algorithmes adaptatifs .....	49
II.4.1.3.	Choix de l'algorithme .....	50
II.5.	MODELES DE CANAL DE PROPAGATION.....	54
II.6.	CONCLUSION .....	55

<b>CHAPITRE III : RÉSEAUX DE NEURONES ARTIFICIELS .....</b>	<b>57</b>
---	-----------

III.1.	INTRODUCTION.....	57
III.2.	EGALISATION LINEAIRE.....	57
III.3.	EGALISATION NON LINEAIRE .....	58
III.4.	LES RESEAUX DE NEURONES ARTIFICIELS (ANN) .....	59
III.4.1.	<i>Architecture et fonctionnement</i> .....	60
III.4.2.	<i>Fonctions de transfert</i> .....	60
III.4.3.	<i>Entraînement des réseaux de neurones</i> .....	60
III.4.4.	<i>MultiLayer Perceptron (MLP)</i> .....	62
III.4.4.1.	Rétropropagation du gradient .....	62
III.4.4.2.	Equations du réseau .....	64
III.4.4.3.	Adaptation des poids.....	65
III.4.4.4.	Problèmes du Back-Propagation .....	67
III.4.5.	<i>Radial Basis Function (RBF)</i> .....	68
III.4.5.1.	Types d'apprentissage.....	68
III.4.5.2.	Apprentissage des réseaux RBF.....	69
III.4.5.3.	Equations du réseau .....	71
III.5.	CONCLUSION .....	72

<b>CHAPITRE IV : OPTIMISATION NEURONALE DE HOM EN RÉSEAUX MOBILE .....</b>	<b>74</b>
--	-----------

IV.1.	INTRODUCTION.....	74
IV.2.	EGALISATION ANN EN LITTERATURE .....	74
IV.3.	MODELE DU SYSTEME .....	75
IV.3.1.	<i>Modèle du canal et génération des symboles</i> .....	75
IV.3.2.	<i>Paramètres de LMS et RLS</i> .....	77
IV.3.3.	<i>Design de l'architecture MLP &amp; RBF</i> .....	79
IV.3.3.1.	Stratégies.....	79
IV.3.3.2.	Valeurs complexes.....	79
IV.3.3.3.	MLP .....	80
IV.3.3.4.	RBF.....	83
IV.4.	SIMULATION & RESULTATS .....	84
IV.4.1.	<i>Récapitulatif sur les réseaux MLP et RBF</i> .....	84
IV.4.2.	<i>Evaluation en termes de MSE</i> .....	86
IV.4.3.	<i>Tracking</i> .....	88
IV.4.4.	<i>Evaluation en termes de BER</i> .....	92

---

IV.4.4.1.	16 QAM.....	92
IV.4.4.2.	64 QAM.....	92
IV.4.4.3.	128 QAM.....	93
IV.4.4.4.	256 QAM.....	93
IV.4.4.5.	512 QAM.....	96
IV.4.4.6.	1024 QAM.....	97
IV.4.5.	<i>Profilage des égaliseurs</i> .....	98
IV.5.	CONCLUSION .....	98
<b>CONCLUSION GÉNÉRALE.....</b>		<b>100</b>
<b>RÉFÉRENCES .....</b>		<b>102</b>
<b>TRAVAUX SCIENTIFIQUES RÉALISÉS.....</b>		<b>108</b>

# Acronymes & abréviations

<b>2D</b>	Bidimensional.
<b>3D</b>	Three Dimensions.
<b>ANN</b>	Artificial neural network.
<b>AWGN</b>	Additive White Gaussian Noise.
<b>BER</b>	Bit Error Rate.
<b>BP</b>	Back Propagation.
<b>BPSK</b>	Binary Phase Shift Keyed.
<b>CA</b>	Carrier Aggregation.
<b>CC</b>	Component Carrier.
<b>CDMA</b>	Code Division Multiple Access.
<b>CFO</b>	Carrier Frequency Offset.
<b>CLMS</b>	Complex LMS.
<b>CMA</b>	Constant Modulo Algorithm.
<b>CP</b>	Cyclic Prefix.
<b>CRLS</b>	Complex RLS.
<b>CRS</b>	Cell-specific Reference Signal.
<b>D/A</b>	Digital to Analogue conversion.
<b>DC</b>	Direct Current subcarrier.
<b>DFE</b>	Decision Feedback Equalization.
<b>DFT</b>	Discrete Fourier Transform.
<b>DFTS-OFDM</b>	DFT Spread-OFDM.
<b>DL</b>	DownLink.
<b>DM-RS</b>	Demodulation Reference Signal.
<b>DVB</b>	Digital Video Broadcasting.
<b>EDGE</b>	Enhanced Data for Global Evolution.

<b>eNB</b>	E-UTRAN Node B / evolved Node B.
<b>E-UTRA</b>	Evolved Universal Terrestrial Radio Access.
<b>EVM</b>	Error Vector Magnitude.
<b>FAP</b>	Fast Affine Projection Algorithm.
<b>FBMC</b>	Filter Bank Multi-Carrier
<b>FDD</b>	Frequency Division Duplex.
<b>FDM</b>	Frequency Division Multiplexing.
<b>FDMA</b>	Frequency Division Multiple Access.
<b>FFT</b>	Fast Fourier Transform.
<b>FIR</b>	Finite Impulse Response.
<b>FPGA</b>	Field-Programmable Gate Array.
<b>FTF</b>	Fast Transversal Filter.
<b>GA</b>	Genetic Algorithms.
<b>GFDM</b>	General Frequency Division Multiplexing.
<b>GMSK</b>	Gaussian Minimum Phase Shift Keying.
<b>GPP</b>	The 3 <sup>rd</sup> Generation Partner Project.
<b>GPRS</b>	General Packet Radio Service.
<b>GSM</b>	Global System for Mobile communication.
<b>HOM</b>	High Order Modulation.
<b>ICI</b>	Inter-Carrier Interference.
<b>IDFT</b>	Inverse Discrete Fourier Transform.
<b>IFFT</b>	Inverse FFT.
<b>IID</b>	Identically Independent Distribution.
<b>IIR</b>	Infinite Impulse Response.
<b>ISI</b>	Inter-Symbol Interference.
<b>LMS</b>	Least Mean Square.
<b>LOS</b>	Line Of Sight.
<b>LTE</b>	Long Term Evolution.
<b>LTE-A</b>	LTE-Advanced.
<b>LTF</b>	Linear Transversal Filter.
<b>MAC</b>	Medium Access Control/Multiple Access Channel (MU-MIMO).

<b>MAI</b>	Multiple Access Interference.
<b>MIMO</b>	Multiple-In Multiple-Out.
<b>MLP</b>	Multi-Layer Perceptrons.
<b>MLSE</b>	Maximum Likelihood Sequence Estimation.
<b>MPAM</b>	M order of PAM.
<b>MPSK</b>	M order of PSK.
<b>M-QAM</b>	M order of QAM (M=4, 16, 64, 128, 256, 512, 1024).
<b>MSE</b>	Mean Square Error.
<b>MSK</b>	Minimum Phase Shift Keying.
<b>NLMS</b>	Normalised Least Mean Squares.
<b>NLOS</b>	No Line Of Sight.
<b>OFDM</b>	Orthogonal Frequency Division Multiplexing.
<b>OFDMA</b>	Orthogonal Frequency Division Multiple Access.
<b>PAM</b>	Pulse Amplitude Modulation.
<b>PAPR</b>	Peak-to-Average Power Ratio.
<b>PCC</b>	Primary Component Carrier.
<b>PSK</b>	Phase Shift Keying.
<b>QAM</b>	Quadrature Amplitude Modulation.
<b>QoS</b>	Quality of Service.
<b>QPSK</b>	Quarter Phase Shift Keying.
<b>RBF</b>	Radial Basis Function.
<b>RF</b>	Radio Frequency.
<b>RLC</b>	Radio Link Control.
<b>RLS</b>	Recursive Least Square.
<b>RN</b>	Relay Node.
<b>RRC</b>	Radio Resource Control.
<b>RRH</b>	Remote Radio Head.
<b>Rx</b>	3GPP structured standard Releases (R7, R8, ..., R15, R16).
<b>SBS</b>	Symbol-By-Symbol.
<b>SCC</b>	Secondary Component Carrier.
<b>SC-FDMA</b>	Single-Carrier FDMA.

<b>SE</b>	Sequence Estimator.
<b>SFN</b>	Single Frequency Network.
<b>SNR</b>	Signal to Noise Ratio.
<b>TDD</b>	Time Division Duplex.
<b>TDMA</b>	Time Division Multiple Access.
<b>TM</b>	Transparent Mode.
<b>UE</b>	User Equipment.
<b>UFMC</b>	Universal Filtered Multi-Carrier.
<b>UL</b>	UpLink.
<b>xG</b>	x <sup>th</sup> Generation of Wireless Communication Technology (2 <sup>nd</sup> , 2.5, 3 <sup>rd</sup> , 3.5, 4 <sup>th</sup> , 5 <sup>th</sup> ).

# Liste des figures

Figure I.1.	Agrégation de porteuses (source : 3gpp.com) .....	25
Figure I.2.	Agrégation de porteuses : Intra- et inter-bande alternatives (source : 3gpp.com) .....	26
Figure I.3.	Agrégation de porteuses : Cellules de service, chaque porteuse de composantes correspond à une cellule servie (source : 3gpp.com) .....	26
Figure I.4.	Scénarios de déploiement de l'agrégation de porteuses .....	28
Figure I.5.	MIMO : Diversité Spatiale (2x2) .....	30
Figure I.6.	MIMO DL avec signal de pré-codage et de référence pour la démodulation en R8 et R10. CRS est un signal de référence spécifique à une cellule, DM-RS est un signal de référence spécifique à l'UE, également spécifique par flux de données .....	31
Figure I.7.	Concept de l'OFDM .....	33
Figure I.8.	Génération du signal OFDM .....	36
Figure I.9.	Concept des OFDM et OFDMA .....	37
Figure I.10.	Différents schémas d'accès multiple.....	39
Figure II.1.	Egalisation du canal .....	45
Figure II.2.	Egalisation avec apprentissage .....	47
Figure II.3.	Schéma d'un système de filtrage adaptatif .....	48
Figure II.4.	Problème d'estimation linéaire .....	48
Figure III.1.	Un groupement possible des techniques d'égalisations [15] .....	58
Figure III.2.	Structure d'un réseau de neurones.....	59
Figure III.3.	Structure du réseau MLP .....	63
Figure III.4.	Architecture des réseaux RBF .....	70
Figure IV.1.	Concept utilisé pour l'égalisation du canal.....	76



Figure IV.2.	Constellation distordue de symboles 1024 QAM reçus dans l'entrée du récepteur avec SNR = 31 dB .....	77
Figure IV.3.	Convergence des coefficients $w_n$ du LMS sur 500 itérations pour 16 QAM .....	78
Figure IV.4.	Convergence des coefficients $w_n$ du RLS sur 500 itérations pour 16 QAM .....	78
Figure IV.5.	Structure d'un filtre adaptatif split-complex (réel & dual univariable)....	80
Figure IV.6.	Algorithme back-propagation .....	82
Figure IV.7.	Etape de validation du MLP basée sur le MSE and le nombre d'itérations .....	82
Figure IV.8.	Classification de constellation 64 QAM (64 zones de décision) réduite à la classification de symboles complexes divisée (8 zones de décision) ...	85
Figure IV.9.	Structure RBF simplifiée pour la décision des symboles avec une seule entrée, une seule sortie et une seule couche cachée avec le nombre adéquat de neurones .....	85
Figure IV.10.	Effet du SNR sur le MSE des égaliseurs sur 16, 64, et 128 QAM .....	87
Figure IV.11.	Effet du SNR sur le MSE des égaliseurs sur 256, 512 et 1024 QAM ....	87
Figure IV.12.	MSE d'égaliseurs MLP et RBF sur 256 QAM avec le nombre optimal de neurones dans leurs couches caches .....	88
Figure IV.13.	Performances de tracking (suivi) des symboles 64 QAM à SNR=28 dB ....	89
Figure IV.14.	Performances de tracking (suivi) des symboles 128 QAM à SNR=28 dB ...	89
Figure IV.15.	Constellations 64 QAM montrant le processus d'égalisation pour LMS, RLS, RBF et MLP avec SNR = 28 dB .....	90
Figure IV.16.	Performances et robustesse du MLP, RBF, LMS et RLS avec 64 QAM en fonction de l'erreur de parties réelles des symboles sur un ensemble fini .....	91
Figure IV.17.	Courbes de performance BER des égaliseurs avec 16 et 64 QAM .....	93
Figure IV.18.	Courbes de performance BER des égaliseurs avec 128 et 256 QAM .....	94
Figure IV.19.	Courbes BER de l'égaliseur MLP avec de différents nombres de neurones dans la couche cachée pour 256 QAM.....	95
Figure IV.20.	Courbes BER de l'égaliseur RBF avec de différents nombres de neurones dans la couche cachée pour 256 QAM.....	95
Figure IV.21.	Courbes de performance BER d'égaliseurs MLP et RBF sur 256 QAM avec le nombre optimal de neurones dans leurs couches cachées.....	96
Figure IV.22.	Courbes de performance BER des égaliseurs avec 512 et 1024 QAM ...	97

# Introduction générale

La demande croissante en capacité dans les réseaux mobiles est la force motrice derrière l'amélioration des réseaux établis et le déploiement de nouveaux standards de communication mobile dans le monde entier. L'interface air est la plus importante des interfaces dans la plupart des systèmes mobiles. L'importance de cette interface résulte du fait que c'est la seule interface à qui l'abonné mobile est exposé et ses paramètres ne sont pas certains. La qualité de cette interface est capitale ; elle dépend principalement de l'utilisation efficace du spectre de fréquence qui lui est assigné et des techniques d'accès mises en œuvre.

De nombreuses technologies clés pour améliorer l'efficacité du spectre sont prévues notamment le système d'accès non orthogonal : accès par division de fréquence généralisé (GFDM), banque de filtres multi-porteuse (FBMC) et multi-porteuse universelle filtrée (UFMC) [1]. Aussi, de nouvelles techniques d'accès et de multiplexage sont prises en considération comme [2] : mmWave (onde millimétrique), multi-entrées/multi-sorties massives (Massive MIMO) et modulation à ordre supérieur (HOM) comme la modulation 256 QAM.

Une modulation 256 QAM (8 bits / symbole) augmente le débit maximal de 33% par rapport à 64 QAM (6 bits / symbole). De nombreuses études sont menées sur l'utilisation de HOM [3-5] pour améliorer la capacité du système dans les petites cellules et les performances de transmission jusqu'à utiliser la modulation 1024 QAM basée sur l'OFDM. Même si les égaliseurs linéaires sont largement utilisés, ils ont des performances médiocres en ce qui concerne la complexité du HOM et sa sensibilité aux distorsions.

HOM permet une performance supérieure à la modulation d'ordre inférieur, mais présente encore des altérations externes et internes comme l'interférence cellulaire (ICI), la sensibilité aux effets de propagation par trajets multiples (externes), le bruit thermique et les dégradations de qualité (influencées par l'EVM (Error Vector Magnitude) causé par le processus de

fabrication hardware) (internes) [6]. L'utilisation de HOM s'accompagne du coût d'une exigence de SNR (Signal to Noise Ratio) plus élevée.

Les récepteurs classiques (matched filters, récepteurs RAKE) ne sont pas efficaces pour combattre ces diverses sources d'interférence. Pour cela, la suppression d'interférence a été l'objet de beaucoup d'efforts de recherche et plusieurs techniques sont proposées afin de réduire l'effet d'interférence entre symboles (ISI) et l'effet des multiples trajets. Pour empêcher une dégradation sévère des performances, il est nécessaire de compenser la distorsion des canaux. Cette compensation est effectuée par un égaliseur adaptatif linéaire ou non linéaire.

La conversion "RF vers bits" dans l'interface air est un processus complexe comprenant la synchronisation, les corrections de dégradation RF, l'égalisation du canal et la correction d'erreur. Au cours de ce processus, et pour augmenter l'efficacité spectrale, une architecture de codage à haut débit et un traitement de signal parallèle à grande vitesse sont nécessaires, d'où l'importance de développer de nouveaux égaliseurs RF non linéaires.

Les réseaux de neurones artificiels (ANN) utilisés comme des égaliseurs non linéaires gagnent de l'importance dans l'égalisation des canaux pour leur architecture flexible, leur optimisation et leur processus d'apprentissage (rétropropagation, filtre de Kalman étendu, algorithmes génétiques et technique d'optimisation Swarm) [7]. Dans ce travail, MLP et RBF sont considérés pour leur simplicité d'architecture et leur facilité d'utilisation, et en particulier pour leurs différentes techniques d'apprentissage. Pour le MLP, nous allons nous concentrer sur l'algorithme de rétropropagation. Le RBF est basé sur la norme euclidienne.

Le problème d'égalisation est traité comme un processus de classification qui indique à quel ensemble appartient le symbole reçu et prend la décision nécessaire. Nous montrerons l'efficacité des MLP et RBF développés par rapport aux récepteurs conventionnels avec HOM en diminuant les critères MSE et BER.

Dans cette thèse, nous développerons les deux techniques d'égalisation linéaire et non linéaire ; nous nous intéresserons aux algorithmes les plus utilisés dans l'égalisation adaptative linéaire qui sont LMS et RLS pour l'égalisation adaptative avec apprentissage. Puis nous proposerons de concevoir deux égaliseurs non linéaires basés sur deux modèles de réseaux de neurones MLP et RBF dans le but d'optimiser les performances du traitement, de poursuite, et de minimiser l'erreur vis-à-vis des effets du canal et du bruit ascendant. Le canal d'évanouissement de Rayleigh sera utilisé en raison de ses bonnes approximations et équitables de l'évanouissement par trajets multiples dans la vie réelle.

Outre une introduction et une conclusion générales, cette thèse est divisée en quatre chapitres.

Le premier chapitre introduit des généralités concernant les réseaux mobiles 4G (LTE-A) notamment les propriétés de la couche physique, les techniques utilisées, les conceptions cellulaires, les duplexages utilisés, ainsi que les techniques d'accès et leurs avantages et inconvénients.

Le deuxième chapitre décrit les types de modulations, spécialement la modulation à ordre supérieure (M-QAM) et l'égalisation du canal. Les égaliseurs ont été conçus et entraînés par des symboles M-QAM (M est l'ordre de modulation) sur une onde porteuse de multiplexage par répartition orthogonale de la fréquence (OFDM) dans un canal de Rayleigh à évanouissement plat.

Le troisième chapitre présente notre contribution au problème d'égalisation HOM. Les conceptions d'égaliseurs non linéaires grâce aux réseaux de neurones MLP et RBF sont explicités.

Le quatrième chapitre est consacré aux résultats de simulation. Les différentes simulations prennent en compte la génération du modèle du canal et la comparaison en termes de MSE, BER et profilage des égaliseurs proposés avec les égaliseurs linéaires classiques.

**Chapitre I :**  
**LTE-Advanced et sa couche**  
**physique**

# Chapitre I :

## LTE-Advanced et sa couche physique

### I.1. Introduction

Aujourd'hui, la 4G LTE est sans aucun doute la norme de référence pour la plupart des opérateurs du monde entier en ce qui concerne les hauts débits mobiles ; la 3G et d'autres technologies plus anciennes étant généralement considérées comme des vitesses de second niveau. A noter que la 4G LTE-A est basée essentiellement sur la modulation MIMO-OFDM. Dans ce qui suit, nous allons décrire cette technologie en termes de couche physique, de techniques d'accès utilisées notamment agrégation des porteuses, MIMO et de modulation OFDM.

### I.2. LTE-A

En LTE-Advanced, l'accent est mis sur une capacité plus élevée : la force motrice pour développer davantage LTE vers LTE-Advanced (LTE Release10) était de fournir des débits plus élevés de manière rentable et, en même temps, de répondre pleinement aux exigences établies par l'UIT (Union Internationale des Télécommunications). L'utilisation de la LTE-A a pour but de :

- Augmenter le pic de débit de données : DL 3 Gbps, UL 1,5 Gbps.
- Efficacité spectrale plus élevée d'un maximum de 16 bps / Hz dans la R8 à 30 bps / Hz dans la R10.
- Augmenter le nombre d'abonnés actifs.
- Performances améliorées aux bords des cellules ; par exemple pour DL 2x2 MIMO au moins 2,40 bps / Hz / cellule [8].

### I.2.1. Avantages de la LTE-A

Le long de sa normalisation, la LTE a été conçue comme une évolution de l'héritage de la troisième génération des systèmes mobiles (3G) en raison de l'incorporation d'un ensemble d'améliorations technologiques, telles que :

- Allocation dynamique d'une bande passante variable.
- Nouveaux schémas MIMO.
- Nouvelle stratégie de transmission avec plusieurs porteuses, comme l'OFDM dans le DownLink et la DFT Spread-OFDM (DFTS-OFDM), également connue sous le nom d'accès multiple par répartition en fréquence unique (SC-FDMA), dans le UpLink.
- Très faible latence [9].

Les principales nouvelles fonctionnalités introduites dans la LTE-A sont l'agrégation de porteuses (Carrier Aggregation), l'utilisation améliorée des techniques multi-antennes (MIMO) et la prise en charge des nœuds de relais (RN) [8].

### I.2.2. Techniques d'accès

Les principales techniques d'accès multiple utilisées en communications sans fil tirent le plus souvent leur origine dans les communications filaires ; elles ont dû être adaptées aux communications sans fils et dont les deux différences principales sont :

- Une bande passante limitée,
- Une communication non fiable (taux d'erreurs élevé, perte de lien, ... etc.)

Le choix d'une technique d'accès (FDMA, TDMA, CDMA, ou une combinaison de deux d'entre elles) peut avoir un impact important sur les performances, la QoS (Quality of Service) et la capacité du système. Ce choix est tellement prépondérant (en tous cas dans l'esprit des concepteurs) qu'on dénomme souvent les systèmes en fonction de l'accès multiple [10].

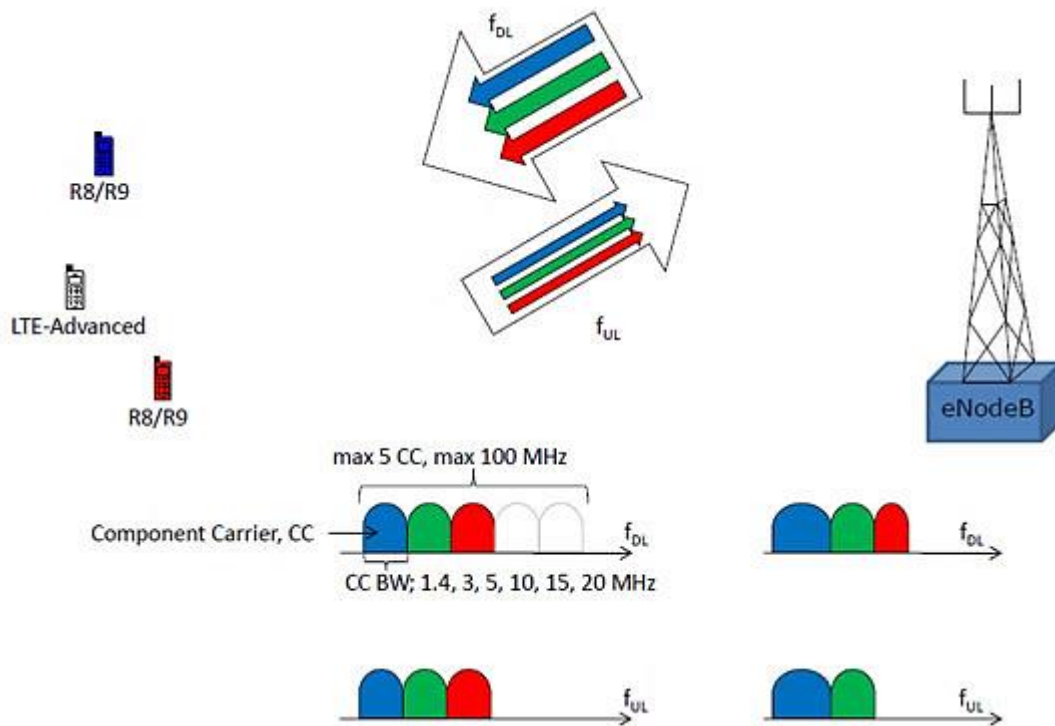
### **I.2.3. Agrégation de porteuses (Carrier Aggregation)**

Le moyen le plus simple d'augmenter la capacité consiste à élargir la bande passante. Comme il est important de conserver la compatibilité ascendante avec les normes 3GPP mobiles R8 et R9, l'augmentation de la bande passante dans la LTE-A est fournie par l'agrégation de porteuses R8 / R9. L'agrégation de porteuse peut être utilisée à la fois pour le FDD et le TDD.

Chaque porteuse agrégée est appelée porteuse de composant. Le support de composant peut avoir une largeur de bande de 1,4 ; 3 ; 5 ; 10 ; 15 ou 20 MHz avec un maximum de cinq composants pouvant être agrégés. Par conséquent, la bande passante maximale est de 100 MHz. Le nombre de porteuses agrégées peut être différent dans les liaisons DL et UL, mais le nombre de porteuses de composant UL n'est jamais supérieur au nombre de porteuses de composantes DL. Les supports de composants individuels peuvent également avoir des largeurs de bande différentes, voir figure I.1.

Pour des raisons pratiques, différentes configurations d'agrégation de porteuses sont spécifiées. Dans la R10, il y a deux porteuses de composantes dans le DL et une seule dans l'UL (donc pas d'agrégation de porteuses dans l'UL). Dans la R11 il y a deux porteuses de composantes DL et une ou deux composantes dans l'UL quand l'agrégation de porteurs est utilisée.






**Figure I.11.** Agrégation de porteuses (source : 3gpp.com)

Le moyen le plus simple d'organiser l'agrégation consiste à utiliser des porteuses de composants contigus dans la même bande de fréquences de fonctionnement (telle que définie pour la LTE) ; ce que l'on appelle l'intra-bande contiguë. Cela n'est pas toujours possible en raison des scénarios d'allocation de fréquences. Pour une attribution non contiguë, il peut s'agir d'une intra-bande, c'est-à-dire que les porteuses composantes appartiennent à la même bande de fréquences de fonctionnement, mais sont séparées par un intervalle de fréquence ou inter-bande ; dans ce cas, les porteuses de composants appartiennent à des bandes de fréquence de fonctionnement différentes, comme l'illustre la figure I.2.


Lorsque l'agrégation de porteuse est utilisée, il existe un certain nombre de cellules servies, une pour chaque porteuse de composante. La couverture des cellules servies peut différer en raison, par exemple, des fréquences des porteuses de composante. La connexion RRC est gérée par une cellule ; la cellule primaire est servie par la porteuse de composant primaire (DL et UL PCC). Les autres porteuses de composante sont toutes appelées porteuses de composante

secondaire (DL et éventuellement UL SCC), desservant les cellules servies secondaires.



*Figure I.12. Agrégation de porteuses : Intra- et inter-bande alternatives (source : 3gpp.com)*

Dans l'exemple de l'agrégation de porteuses inter-bande représenté sur la figure I.3, l'agrégation de porteuse sur les trois porteuses de composantes n'est possible que pour l'UE noir, l'UE blanc n'est pas dans la zone de couverture de la porteuse de composante rouge.



**Figure I.13.** Agrégation de porteuses : Cellules de service, chaque porteuse de composantes correspond à une cellule servie (source : 3gpp.com)

L'introduction de l'agrégation des porteuses influence principalement le MAC et le protocole de la couche physique, mais le tampon RLC doit être plus grand et le RRC doit être capable de prendre des décisions sur l'ajout / l'élimination du CC secondaire.

#### I.2.4. Scénarios de déploiement

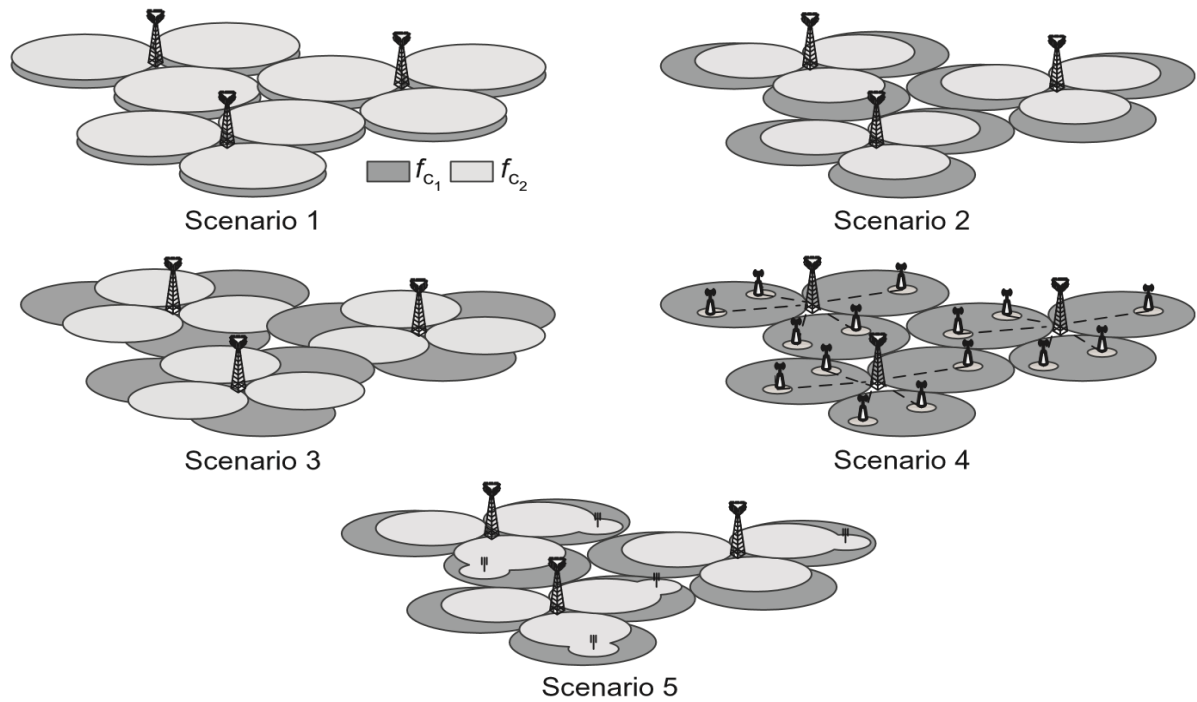
L'agrégation de porteuse permet divers déploiements de réseau. En général, elle est utilisée pour améliorer les débits de données pour les utilisateurs dans des zones des cellules chevauchantes (limites de cellules). Cependant, l'agrégation de porteuse peut également être utilisée pour atténuer les interférences entre cellules dans des réseaux hétérogènes. Les scénarios de déploiement réseau suivants ont été pris en compte lors du développement de la LTE-A.

Bien qu'illustré avec des porteuses à deux composantes aux fréquences  $f_{c1}$  et  $f_{c2}$  comme le montre la Figure I.4, le concept peut être généralisé à n'importe quel nombre de porteuses de composantes :

**Scénario de déploiement 1 :** Dans ce cas, les cellules avec les fréquences porteuses  $f_{c1}$  et  $f_{c2}$  sont (géographiquement) co-localisées, et leur couverture est superposée avec  $f_{c1}$  et  $f_{c2}$  dans la même bande de fréquence. Elles offrent approximativement la même couverture. Ce scénario d'agrégation de porteuses atteint des débits de données plus élevés dans toute la cellule, où les deux couches offrent une couverture et une mobilité suffisantes. Un exemple de scénario est le cas où  $f_{c1} = 2000$  MHz et  $f_{c2} = 800$  MHz sont de la même bande où l'agrégation est possible entre les cellules superposées.

**Scénario de déploiement 2 :** Dans ce cas, les cellules avec les fréquences porteuses  $f_{c1}$  et  $f_{c2}$  sont co-localisées et superposées avec  $f_{c1}$  et  $f_{c2}$  dans différentes bandes de fréquence. Une couverture différente est fournie sur différentes

porteuses en raison de la plus grande perte de trajet dans la bande de fréquence supérieure. La mobilité est généralement prise en charge sur le support dans la bande de fréquence inférieure, ce qui fournit en outre une couverture suffisante. La porteuse dans la bande de fréquence supérieure est utilisée pour améliorer les débits de données. Les cellules  $f_{c1}$  et  $f_{c2}$  sont co-localisées et superposées, mais  $f_{c2}$  a une couverture plus faible en raison d'une perte plus importante de trajet. En d'autres termes, seul  $f_{c1}$  fournit une couverture suffisante et  $f_{c2}$  est utilisée pour améliorer le débit. Un exemple de scénario serait le cas où  $f_{c1} = \{800 \text{ MHz}, 2000 \text{ MHz}\}$  et  $f_{c2} = 3500 \text{ MHz}$  où l'agrégation est possible entre les cellules superposées.



**Figure I.14.** Scénarios de déploiement de l'agrégation de porteuses.

**Scénario de déploiement 3 :** Dans ce cas, les cellules comprenant les fréquences porteuses  $f_{c1}$  et  $f_{c2}$  sont co-localisées avec  $f_{c1}$  et  $f_{c2}$  dans différentes bandes de fréquences. Les antennes pour les cellules de  $f_{c2}$  sont dirigées vers les limites des cellules de  $f_{c1}$  pour améliorer les débits de données au bord des cellules. En raison de perte de trajet plus importante, il existe des trous de couverture pour les cellules de la bande de fréquences supérieures sur lesquelles


la gestion de la mobilité n'est généralement pas effectuée. L'agrégation de porteuse est prise en charge dans les zones avec couverture de chevauchement et la mobilité est basée sur la couverture  $f_{c1}$ . Un exemple serait le cas où  $f_{c1} = \{800 \text{ MHz}, 2000 \text{ MHz}\}$  et  $f_{c2} = 3500 \text{ MHz}$  dans lequel l'agrégation est possible entre les cellules superposées.

**Scénario de déploiement 4 :** Dans ce cas, les cellules associées à la fréquence porteuse  $f_{c1}$  assurent une macro-couverture et des têtes radio distantes (RRH) correspondant à la fréquence porteuse  $f_{c2}$  sont utilisées pour améliorer le débit aux points chauds. La mobilité est effectuée sur la base de la couverture cellulaire de fréquence  $f_{c1}$ . Dans ce scénario de déploiement, les fréquences porteuses  $f_{c1}$  et  $f_{c2}$  sont généralement de bandes différentes. L'agrégation de porteuses est applicable aux utilisateurs dans la couverture des RRH et des macro-cellules sous-jacentes. Un exemple serait le cas où  $f_{c1} = \{800 \text{ MHz}, 2000 \text{ MHz}\}$  correspond à une cellule plus grande et  $f_{c2} = 3500 \text{ MHz}$  correspond à une cellule plus petite, dans laquelle l'agrégation est possible entre les cellules superposées.

**Scénario de déploiement 5 :** Ce cas est similaire au deuxième scénario où des répéteurs sélectifs de fréquence ou des systèmes d'antennes distribuées sont en outre déployés pour étendre la couverture pour l'une des fréquences porteuses. On s'attend à ce que les cellules  $f_{c1}$  et  $f_{c2}$  du même eNB puissent être agrégées là où la couverture se chevauche [11].

### I.2.5. MIMO

Le MIMO est utilisé pour augmenter le débit global en transmettant deux (ou plus) flux de données différents sur deux (ou plus) antennes différentes, en utilisant les mêmes ressources en fréquence et en temps, séparées uniquement par l'utilisation de signaux de références différentes. La réception est faite par deux antennes ou plus, voir figure I.5.



**Figure I.15.** MIMO : Diversité Spatiale (2x2).

Pour être en mesure d'ajuster le type de schéma de transmission multi-antennes (selon l'environnement radio), un certain nombre de modes de transmission différents (TM) a été défini. L'UE doit, par le biais de la signalisation RRC, être informé du mode de transmission à utiliser. Dans le DL, il y a neuf modes de transmission différents, où TM1-7 ont été introduits dans R8, TM8 a été introduit dans R9 et TM9 a été introduit dans R10. Dans l'UL, il y a TM1 et TM2, où TM1, par défaut, a été introduit dans R8 et TM2 a été introduit dans R10. Les différents modes de transmission diffèrent en :

- Nombre de couches (flux ou rang).
- Ports d'antenne utilisés.
- Type de signal de référence, signal de référence spécifique à une cellule (CRS) ou signal de référence de démodulation (DM-RS), introduit dans R10.
- Type de pré-codage.

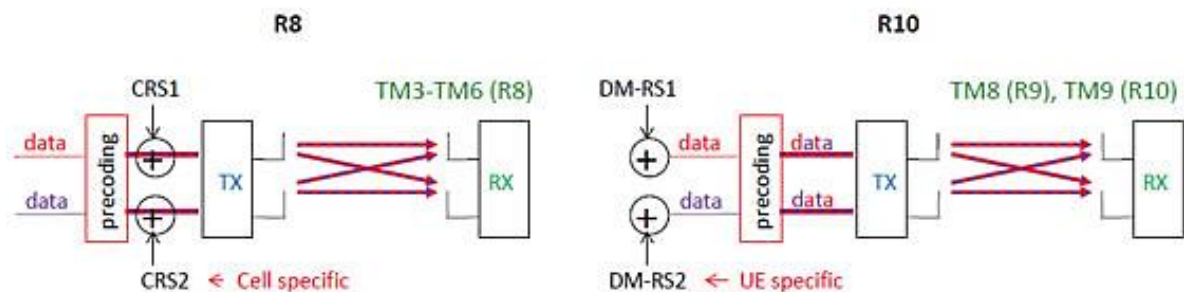
Grâce à l'introduction de TM9 8x8 MIMO est pris en charge dans la liaison DL ; et grâce à l'introduction de TM2 dans la liaison UL l'utilisation de 4x4 MIMO UL est possible. Naturellement, il est également nécessaire que l'UE supporte cela. Dans R10, trois nouvelles catégories d'UE sont introduites, catégories 6, 7 et 8 où la catégorie UE 8 prend en charge le nombre maximal de CC et le multiplexage spatial 8x8.

Dans les techniques multi-antennes, le pré-codage est utilisé pour cartographier les symboles de modulation sur les différentes antennes. Le type de pré-codage dépend de la technique multi-antenne utilisée ainsi que du nombre de couches et du nombre de ports d'antennes. Le but du pré-codage est d'obtenir la meilleure réception de données possible au niveau du récepteur.

A Noter que le signal sera influencé par différents types d'évanouissements ; ce qui peut également être vu comme un type de "codage" provoqué par le canal radio. Pour gérer cela, des signaux de référence connus seront transmis avec les données, et utilisés par le récepteur pour la démodulation du signal reçu.

En R8, le signal de référence est ajouté au signal après pré-codage ; il est spécifique à chaque une antenne. A partir du CRS reçu, l'UE estime comment le canal radio a influencé le signal. En utilisant ceci conjointement avec la connaissance du pré-codage basé sur un codebook utilisé, l'UE peut démoduler le signal reçu et régénérer l'information envoyée.

En R10, les DM-RS (Demodulation Reference Signals) sont ajoutés aux différents flux de données avant le pré-codage. La connaissance du signal de référence fournira des informations sur l'influence combinée du canal radio et du pré-codage, aucune pré-connaissance du pré-codeur n'est requise par le récepteur ; ce cas est appelé pré-codage non-codebook, voir figure I.6 [12, 13].



**Figure I.16.** MIMO DL avec signal de pré-codage et de référence pour la démodulation en R8 et R10. CRS est un signal de référence spécifique à une cellule, DM-RS est un signal de référence spécifique à l'UE, également spécifique par flux de données.

### I.3. OFDM

Le multiplexage par répartition orthogonale de la fréquence (OFDM) est une forme de technique de modulation multi-porteuse qui a été introduite il y a plus de 50 ans. Dans un système de transmission de données en série classique, les symboles portant des informations sont transmis de manière séquentielle ; le spectre de fréquence de chaque symbole occupe toute la bande passante disponible. La figure I.7 illustre un spectre de signal de modulation d'amplitude en quadrature non filtrée (QAM). Il est sous la forme de  $\sin(\pi f T_u)/\pi f T_u$  avec des points de passage à zéro à des multiples entiers de  $1/T_u$ , où  $T_u$  est la période du symbole QAM. Le concept OFDM consiste à transmettre les bits de données dans des sous-porteuses modulées en modulation QAM parallèles en utilisant le multiplexage par répartition en fréquence. L'espacement des porteuses est soigneusement choisi de telle sorte que chaque sous-porteuse se trouve sur les points de zéros de croisement d'autres sous-porteuses dans le domaine fréquentiel. Bien qu'il y ait des chevauchements spectraux entre les sous-porteuses, elles n'interfèrent pas les unes avec les autres si elles sont échantillonnées aux fréquences des sous-porteuses. En d'autres termes, elles ont une orthogonalité spectrale. Comme le montre la figure I.7, le signal OFDM dans le domaine fréquentiel est généré par  $N_{FFT}$  agrégation de sous-porteuses modulées en QAM parallèles, où les sous-porteuses adjacentes sont séparées par l'espacement de sous-porteuse  $1/T_u$ . Comme un signal OFDM est constitué de plusieurs sous-porteuses QAM parallèles, l'expression mathématique du signal dans le domaine temporel peut être exprimée comme suit :

$$s(t) = Re \left\{ e^{j\omega_c t} \sum_{k=-\frac{N_{FFT}-1}{2}}^{\frac{N_{FFT}-1}{2}} \alpha_k e^{\frac{j2\pi k(t-t_g)}{T_u}} \right\} \quad (I.1)$$

où  $s(t)$  désigne le signal OFDM dans le domaine temporel,  $\alpha_k$  est la donnée complexe qui est modulée en QAM et transmise sur la sous-porteuse  $k$ ,  $N_{FFT}$  est le nombre de sous-porteuses dans le domaine fréquentiel,  $\omega_c$  est la fréquence porteuse RF, et  $t_g$  est l'intervalle de garde ou la longueur du préfixe cyclique (CP).



Pour un grand nombre de sous-porteuses, la génération directe et la démodulation du signal OFDM nécessiteraient des réseaux de générateurs sinusoïdaux cohérents qui peuvent devenir excessivement complexes et coûteux.

Cependant, on peut remarquer que le signal OFDM est en fait la partie réelle de la transformée de Fourier discrète inverse (IDFT) des symboles de données à valeur complexe  $\{\alpha_k\}_{k=-N_{FFT}/2, \dots, N_{FFT}/2}$ .

On peut voir qu'il y a  $N < N_{FFT}$  sous-porteuses, chacune véhicule les correspondantes données  $\alpha_k$ . L'inverse de l'espacement de sous-porteuse  $\Delta f = 1/T_u$  est défini comme la durée du symbole OFDM utile  $T_u$ , qui est  $N_{FFT}$  fois plus longue que celle de la durée du symbole de données d'entrée d'origine.




Figure I.17. Concept de l'OFDM.

Comme l'IDFT est utilisée dans le modulateur OFDM, les données d'origine sont définies dans le domaine fréquentiel, tandis que le signal OFDM  $s(t)$  est défini dans le domaine temporel. L'IDFT peut être implémentée via un algorithme de transformée de Fourier rapide (FFT). L'orthogonalité des sous-porteuses en OFDM peut être maintenue et les sous-porteuses individuelles peuvent être complètement séparées et démodulées par une FFT au niveau du récepteur lorsqu'il n'y a pas d'ISI introduite par le canal de communication. En pratique, les distorsions linéaires telles que le retard par trajets multiples provoquent l'ISI entre les symboles OFDM, ce qui entraîne une perte d'orthogonalité et un effet similaire à l'interférence co-canal. Cependant, lorsque la propagation de retard est petite, c'est-à-dire dans une fraction de la longueur de symbole OFDM utile, l'impact d'ISI est insignifiant, bien qu'il dépende de l'ordre de modulation mis en œuvre par les sous-porteuses.

### I.3.1. Préfixe cyclique

Une solution simple pour atténuer le retard de propagation par trajets multiples consiste à augmenter la durée de symbole OFDM efficace de telle sorte qu'elle soit beaucoup plus grande que la propagation de retard ; cependant, lorsque la propagation du retard est importante, elle nécessite un grand nombre de sous-porteuses et une grande taille de FFT. Pendant ce temps, le système pourrait devenir sensible au décalage Doppler et au décalage de fréquence porteuse (CFO). Une approche alternative pour atténuer la distorsion par trajets multiples consiste à générer un intervalle de garde étendu cycliquement, où chaque symbole OFDM est préfixé d'une extension périodique du signal lui-même, comme le montre la figure I.8 où la queue du symbole est copiée au début du symbole. La durée du symbole OFDM est alors définie par  $T_s = T_u + T_g$ , où  $T_g$  est l'intervalle de garde ou le préfixe cyclique. Lorsque l'intervalle de garde est plus long que la réponse impulsionnelle du canal ou le retard de propagation par trajets multiples, l'ISI peut être efficacement éliminée.

### I.3.2. Génération de la porteuse OFDM

Un diagramme d'émetteur OFDM est illustré à la figure I.8. Le flux binaire entrant est modulé en QAM pour former les symboles QAM à valeurs complexes. Les symboles QAM sont convertis de série en parallèle avec  $N < N_{FFT}$  nombres à valeurs complexes par bloc, où  $N_{FFT}$  est la taille de l'opération FFT / IFFT. Chaque bloc est traité par une IFFT et la sortie de l'IFFT forme un symbole OFDM qui est reconverti en données série pour la transmission. Un intervalle de garde ou un préfixe cyclique est inséré entre les symboles pour éliminer les effets ISI causés par la distorsion par trajets multiples. Les symboles discrets sont filtrés et convertis en analogique pour la conversion ascendante RF. Le processus inverse est effectué au niveau du récepteur. Un égaliseur à une prise (one-tap) est généralement utilisé pour chaque sous-porteuse pour corriger la distorsion de canal. Les coefficients de prise (tap) sont calculés sur la base des informations du canal [11].

### I.3.3. Egaliseur OFDM & multi-trajets

Lorsqu'il y a distorsion par trajets multiples, un système de transmission à large bande à porteuse unique classique souffre d'un évanouissement sélectif en fréquence. Un égaliseur adaptatif complexe doit être utilisé pour égaliser les évanouissements dans la bande. Le nombre de prises nécessaires pour l'égaliseur est proportionnel au débit de symboles et au retard de propagation par trajets multiples. Pour un système OFDM, si l'intervalle de garde est supérieur au délai de propagation par trajets multiples, l'ISI peut être éliminé et l'orthogonalité peut être maintenue parmi les sous-porteuses. Comme chaque sous-porteuse OFDM occupe un spectre très étroit, de l'ordre de quelques kHz, même en cas de forte distorsion par trajets multiples, les sous-porteuses ne sont sujets qu'à un évanouissement uniforme. En d'autres termes, l'OFDM convertit un canal d'évanouissement sélectif en fréquence à large bande en une série de sous-canaux d'évanouissement non sélectifs en fréquence à bande étroite en utilisant le schéma de transmission multi-porteuses parallèles. Comme les sous-porteuses de données OFDM sont statistiquement indépendantes et distribuées de manière

identique (IID), sur la base du théorème de la limite centrale, lorsque le nombre de sous-porteuses  $N_{FFT}$  est important, la distribution du signal OFDM tend à être gaussienne.

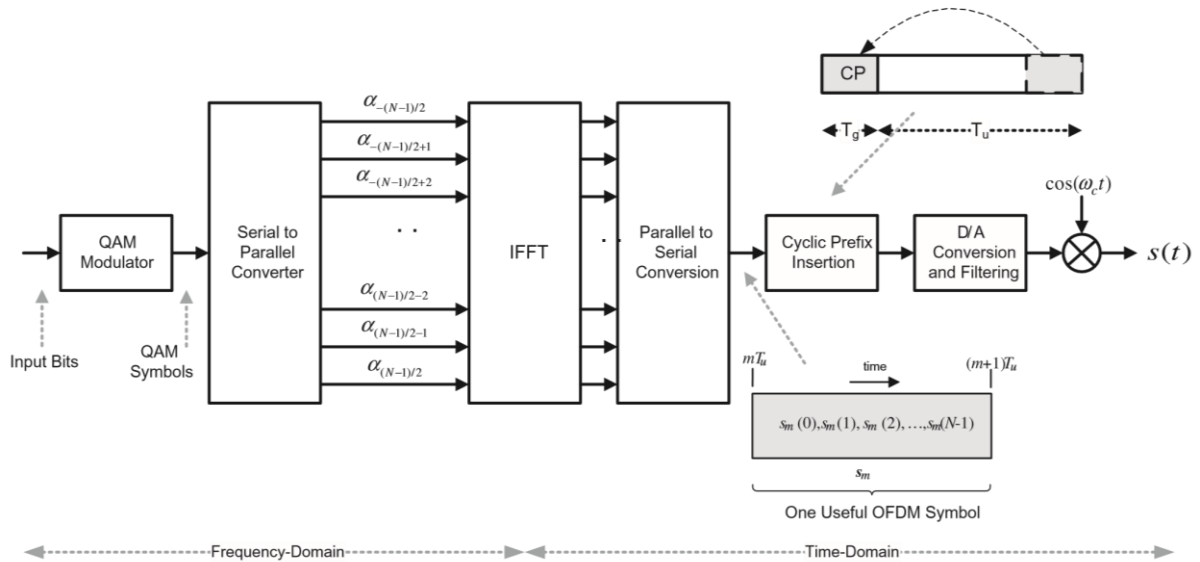
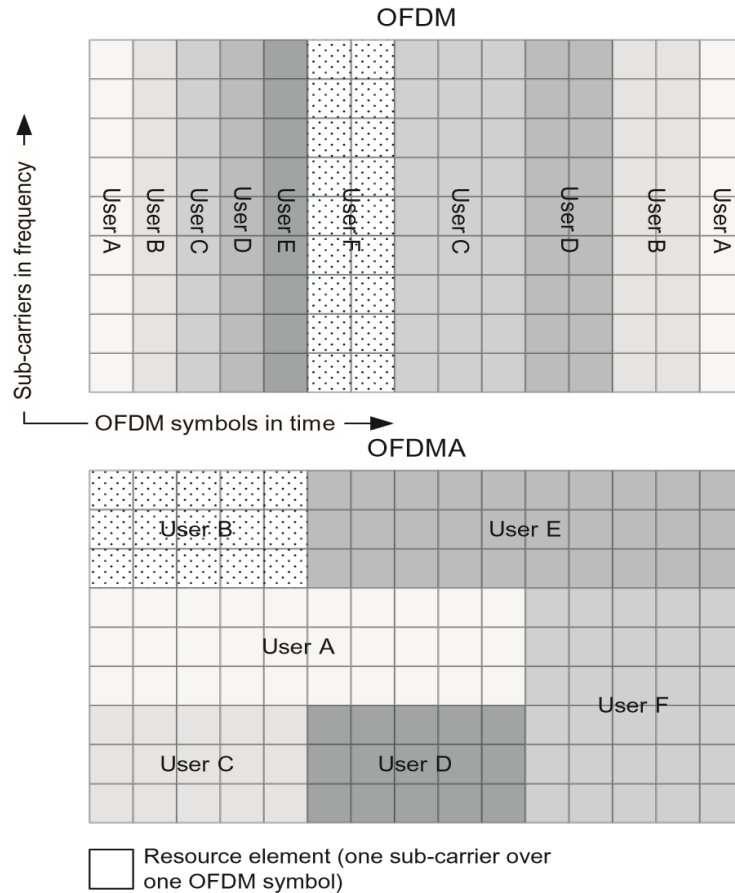


Figure I.18. Génération du signal OFDM

### I.3.4. Accès multiple (OFDMA)

L'accès multiple par répartition orthogonale de la fréquence (OFDMA) est la variante multi-utilisateur du schéma OFDM où l'accès multiple est obtenu en affectant des sous-ensembles de sous-porteuses à différents utilisateurs, permettant une transmission simultanée de données de plusieurs utilisateurs. Dans l'OFDMA, les ressources radio sont des régions bidimensionnelles (2D) en temps (un nombre entier de symboles OFDM) et en fréquence (un nombre de sous-porteuses contiguës ou non contiguës). La différence entre OFDM et OFDMA est illustrée à la figure I.9. Similaire à OFDM, OFDMA emploie plusieurs sous-porteuses étroitement espacées, mais les sous-porteuses sont divisées en groupes de sous-porteuses où chaque groupe est appelé un bloc de ressources. Le regroupement de sous-porteuses en groupes de blocs de ressources est appelé sous-canalisation. Les sous-porteuses qui forment un bloc de

ressources n'ont pas besoin d'être physiquement adjacentes. Dans la liaison descendante, un bloc de ressources peut être alloué à différents utilisateurs. Dans la liaison montante, un utilisateur peut être affecté à un ou plusieurs blocs de ressources.



**Figure I.19.** Concept des OFDM et OFDMA

La sous-segmentation définit les sous-canaux qui peuvent être attribués aux stations mobiles en fonction de leurs conditions de canal et des exigences de service. En utilisant le sous-multiplexage, dans le même créneau temporel (c'est-à-dire un nombre entier de symboles OFDM), un système OFDMA peut allouer plus de puissance d'émission aux dispositifs utilisateurs avec un SNR plus faible et moins de puissance aux dispositifs utilisateurs avec un SNR plus élevé. La sous-canalisation permet également à la station de base d'allouer une puissance

plus élevée aux sous-canaux attribués aux terminaux mobiles intérieurs, ce qui améliore la couverture à l'intérieur.

Au cours des dernières années, divers systèmes d'accès multiple ont été utilisés dans les systèmes cellulaires, ce qui permet au réseau de partager les ressources radio disponibles (temps, fréquence, code et espace) entre un certain nombre d'utilisateurs de la cellule du système dans les directions des liaisons descendante et montante. La figure I.10 illustre le concept de partage de ressources dans divers schémas d'accès multiple. Comme mentionné précédemment, OFDMA a été un système d'accès multiple prometteur qui a été récemment utilisé dans les technologies d'accès radio large bande mobile. L'E-UTRA utilise OFDMA et SC-FDMA en tant que schémas d'accès multiple dans les directions DL et UP, respectivement. Les paramètres OFDMA / SC-FDMA pour l'E-UTRA ont été choisis pour faciliter la coexistence avec l'UTRA sur la même plate-forme et partager la même fréquence d'échantillonnage temporel de 30,72 MHz.

En OFDMA, un symbole OFDM est constitué de sous-porteuses, dont le nombre est déterminé par la taille FFT. Il existe plusieurs types de sous-porteuses :

- (1) Les sous-porteuses de données sont utilisées pour la transmission de données ;
- (2) Des sous-porteuses pilotes ou de signaux de référence sont utilisées pour l'estimation de canal et la détection cohérente ;
- (3) Les sous-porteuses nulles ne sont pas utilisées pour la transmission pilote / données.

Les sous-porteuses nulles, y compris la sous-porteuse DC, sont utilisées pour les bandes de garde. Le nombre de sous-porteuses utilisées (ou occupées) est toujours inférieur à la taille de la FFT / IFFT. Les bandes de garde sont utilisées pour permettre le partage du spectre et réduire les brouillages dans le canal adjacent et les émissions hors bande. La fréquence d'échantillonnage est sélectionnée pour être supérieure ou égale à la bande passante du canal. Le

nombre d'échantillons de temps dans une trame radio est toujours entier ; et pour simplifier davantage la conception du filtre d'émission analogique, la fréquence d'échantillonnage est mise à l'échelle d'un facteur supérieur à un (par exemple, la fréquence d'échantillonnage est de 30,72 MHz).

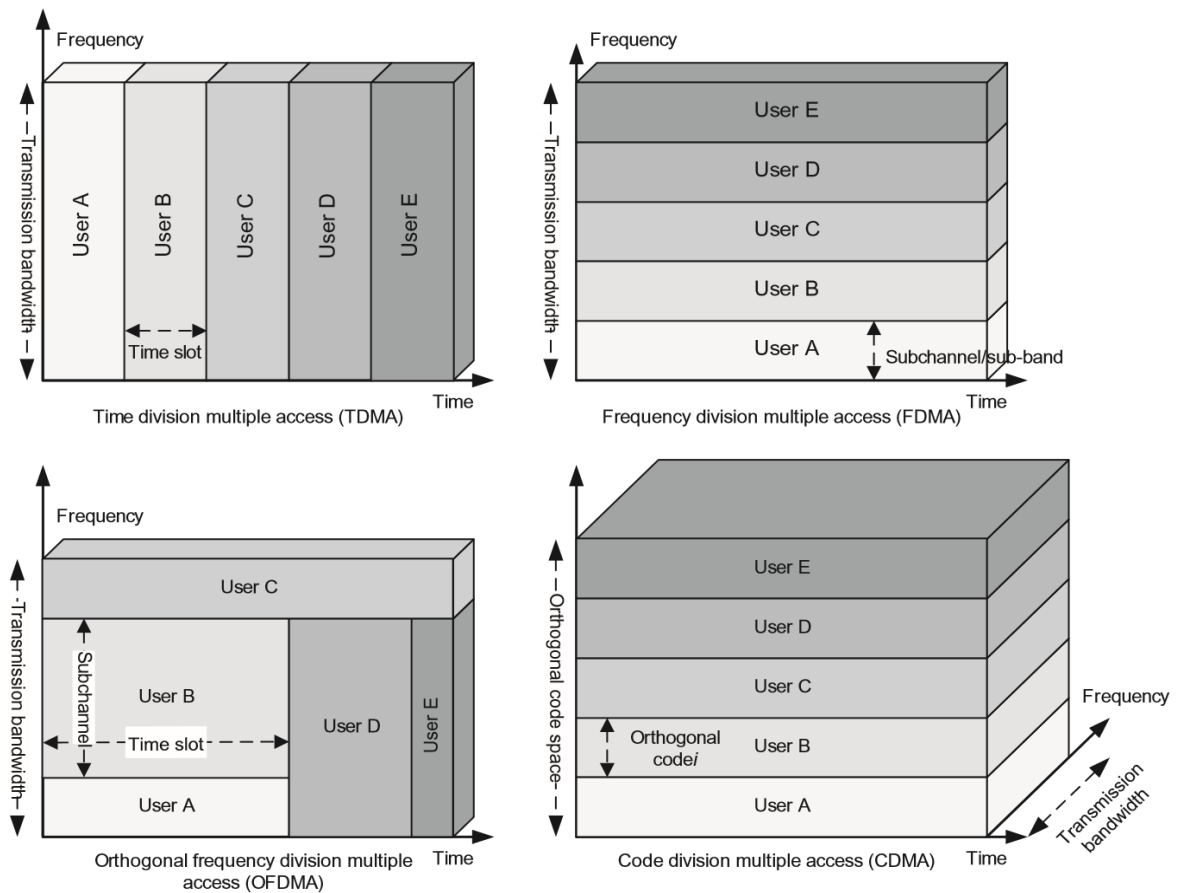


Figure I.20. Différents schémas d'accès multiple.

### I.3.5. Avantages & désavantages

- Efficacité spectrale élevée par rapport à d'autres schémas de modulation à double bande latérale, spectre étalé, ... etc.
- Peut facilement s'adapter à des conditions de canal sévères sans égalisation temporelle complexe.
- Robuste contre les interférences dans le même canal.

- Robuste contre les interférences inter-symboles (ISI) et les évanouissements causés par la propagation par trajets multiples.
- Mise en œuvre efficace en utilisant la transformée de Fourier rapide.
- Faible sensibilité aux erreurs de synchronisation temporelle.
- Les filtres du récepteur de sous-canal accordés ne sont pas requis (contrairement au FDM conventionnel).
- Facilite les réseaux à fréquence unique (SFN) (c'est-à-dire la macro-diversité de l'émetteur).

Malgré ces avantages, l'OFDM dans sa forme actuelle n'est pas un bon candidat pour la 5G à cause de ses inconvénients :

- Sensible au décalage Doppler.
- Sensible aux problèmes de synchronisation de fréquence.
- Taux élevé de puissance crête par rapport à la puissance moyenne (PAPR), nécessitant un circuit d'émission linéaire, qui souffre d'une faible efficacité énergétique.
- Perte d'efficacité causée par le préfixe cyclique / intervalle de garde.

## I.4. Conclusion

Nous avons vu dans ce chapitre les bases de communication dans les réseaux mobiles, notamment le réseau LTE-Advanced qu'on peut qualifier comme la passerelle vers la 5G. Son évolution, son architecture et particulièrement ses avantages ont été explicités. La LTE-A utilise les techniques avancées comme l'agrégation des porteuses et la MIMO combiné avec l'OFDM. Ces derniers sont employés pour une utilisation optimisée du spectre et permettent de pallier les effets néfastes de la couche physique (interface air).

La modulation à ordre élevée et les égaliseurs sont une partie importante à traiter dans la couche physique. Ils seront développés dans le chapitre suivant.



**Chapitre II :**  
**Modulation à ordre supérieur**  
**& égalisation du canal**

# Chapitre II :

## Modulation à ordre supérieur & égalisation du canal

### II.1. Introduction

Dans beaucoup de situations, il est nécessaire de transmettre des signaux numériques, en général, sous forme d'une séquence binaire. Les signaux numériques présentent en effet plusieurs propriétés intéressantes pour les télécommunications : souplesse de traitement, signal à états discrets donc moins sensibles aux bruits et simple à régénérer, utilisation de codes correcteurs d'erreur, cryptage de l'information ...etc. En revanche, nous verrons ultérieurement qu'à quantité d'informations transmise identique, un signal numérique nécessite une bande de fréquence nettement plus importante.

Pour des raisons identiques au cas des signaux analogiques, ces signaux numériques modulent une porteuse sinusoïdale afin de présenter, soit des caractéristiques compatibles avec le canal de transmission utilisé (exemple des modems), soit pour transmettre plusieurs signaux simultanément. Toutefois, c'est l'explosion de la téléphonie mobile et de la télévision numérique qui suscite une étude de ce type de modulations.

## II.2. Types de modulations

### II.2.1. Binary Phase Shift Keyed (BPSK)

La BPSK utilise une phase pour représenter un 1 et une autre pour représenter un 0 (binaire). Elle est utilisée pour transmettre jusqu'à 1 Mb/s.

### II.2.2. Gaussian Minimum Phase-shift Keying (GMSK)

La GMSK est la modulation utilisée pour les signaux en GSM. C'est une méthode de modulation dérivée du déphasage minimum (MSK). Ainsi, elle est basée sur la modulation de fréquence. La modulation GMSK fonctionne avec deux gammes de fréquences et peut basculer facilement entre les deux. L'avantage principal de la GMSK est qu'elle ne contient pas de partie de la modulation d'amplitude, et la largeur de bande exigée de la fréquence de transmission est de 200 kHz, qui est une largeur de bande acceptable par les normes du GSM. C'est la modulation utilisée dans les réseaux GSM et GPRS.

### II.2.3. Octagonal Phase-shift Keying (8-PSK)

La raison derrière le perfectionnement de manipulation de données dans les réseaux 2G tel que le GPRS est l'introduction de l'octogonale PSK (8-PSK). Dans cet arrangement, le signal modulé peut porter 3 bits par symbole modulé à travers le signal radio par rapport à 1 bit dans la modulation GMSK. Mais cette augmentation du flux de données est au coût d'une diminution de la sensibilité du signal radio. Par conséquent, les débits les plus élevés sont fournis dans une couverture partielle. C'est la modulation utilisée dans les réseaux GPRS et EDGE.

### II.2.4. Quarter Phase-Shift Keying (QPSK)

La modulation QPSK est une forme de modulation par déplacement de phase dans laquelle la porteuse est modulé en sélectionnant l'un des quatre déphasages de phase de porteuse possibles (0, 90, 180 ou 270 degrés). La QPSK

peut donc représenter 2 bits binaires de données (quatre symboles). Elle permet au signal de transporter deux fois plus d'informations que la PSK ordinaire en utilisant la même bande passante. Pour cette raison, elle est la modulation choisie pour la téléphonie cellulaire, spécifiquement, les réseaux 3G ; CDMA [14].

### II.2.5. Quadrature Amplitude Modulation (M-QAM)

Pour le M-QAM, les bits d'information sont codés à la fois en amplitude et en phase du signal transmis. Ainsi, alors que MPAM et MPSK ont tous deux un degré de liberté pour coder les bits d'information (amplitude ou phase), le M-QAM a deux degrés de liberté. En conséquence, le M-QAM est plus efficace sur le plan spectral que MPAM et MPSK, en ce sens qu'il peut coder le plus grand nombre de bits par symbole pour une énergie moyenne donnée. [15]

## II.3. HOM

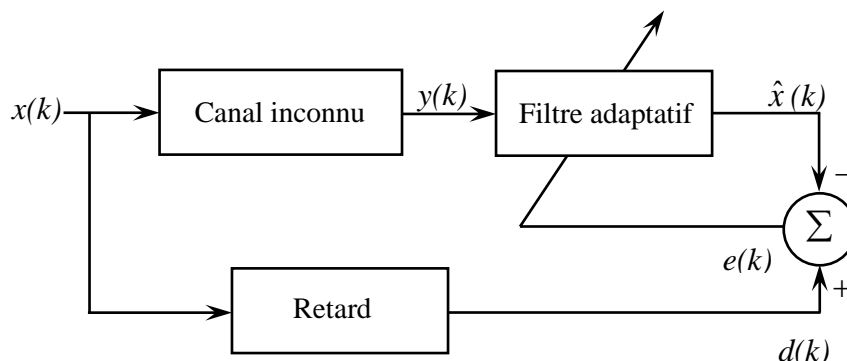
Dans les systèmes de communication câblés, HOM est déjà utilisée pour augmenter l'efficacité de la bande passante comme c'est le cas dans les communications par fibre optique, la télévision câblée (DVB) et les liaisons par satellite. Dans les communications sans fil mobiles, le passage de 64 QAM à 256 QAM augmente théoriquement de 33% l'efficacité du spectre et le débit de données de crête d'un UE, puisque l'ordre de modulation passe de 6 bits / symbole à 8 bits / symbole. Idéalement, en augmentant à 1024 QAM, HOM offre l'efficacité de bande passante la plus élevée disponible, jusqu'à un gain de 66% sur le débit pic de données. La HOM peut offrir un gain de performances supérieur à celui de la modulation d'ordre inférieur, mais il existe encore des effets néfastes internes et externes telles que l'interférence inter-cellulaire (ICI) et la sensibilité aux effets de propagation par trajets multiples (externes), le bruit thermique et les dégradations de qualité. La magnitude (EVM) imposée par des contraintes de fabrication pratiques (internes), employant le HOM, s'accompagne d'une exigence de SNR plus élevée [16].

HOM améliore le système de capacité dans les petites cellules [17] ; dans [18] les performances de transmission avec 256 et 1024 QAM sur OFDM sont étudiées avec l'impact de l'EVM. La mise en œuvre pratique FPGA de HOM est déjà effectuée dans [19] en utilisant des égaliseurs CMA et LMS conventionnels. Dans ce travail, nous allons montrer l'efficacité de MLP et RBF sur les récepteurs conventionnels avec HOM en diminuant les critères MSE et BER / SNR.

## II.4. Egalisation

Si le canal de transmission avait une atténuation constante et un déphasage linéaire sur la bande du signal, il ne modifierait pas la forme des impulsions émises et le récepteur recevrait tout simplement une version bruitée du signal émis. En pratique, ces deux conditions ne sont que très rarement vérifiées et la réponse du canal a besoin d'être égalisée pour éliminer la distorsion du signal reçu.

L'égalisation est une procédure qui est utilisée par les récepteurs des systèmes de communications numériques afin de réduire l'effet d'interférence entre symboles (ISI) due à la propagation du signal modulé à travers le canal. Pour empêcher une dégradation sévère des performances, il est nécessaire de compenser la distorsion du canal. Cette compensation est effectuée par un filtre adaptatif.



**Figure II.1.** Egalisation du canal

Cascader le filtre adaptatif avec le canal (système inconnu) fait converger le filtre adaptatif à une solution qui est l'inverse du canal. Si la fonction de transfert du canal est  $H(z)$  et la fonction de transfert du filtre adaptatif est  $G(z)$  (figure II.1), l'erreur à mesurer entre le signal désiré et le signal du système cascadié atteint son minimum quand le produit de  $H(z)$  et  $G(z)$  est 1. Pour que cette relation soit vraie,  $G(z)$  doit équaler  $1/H(z)$ , l'inverse de la fonction de transfert du canal.

Par ailleurs, la réponse du canal est en général inconnue et, de plus, susceptible de varier au cours du temps. Son égalisation nécessite alors un égaliseur adaptatif capable de s'adapter au canal et de poursuivre ses variations temporelles [20, 21].

Il existe deux types d'égalisations :


- Egalisation avec apprentissage (Training)
- Egalisation sans apprentissage : Aveugle (Blind)

Dans le cas où les propriétés du canal sont connues à l'avance, il est possible d'initialiser le filtre avant que la transmission commence. Si le canal n'est pas maîtrisé, les paramètres de l'égaliseur doivent être estimés. Les méthodes standards utilisent ce qu'on appelle des séquences d'apprentissage : l'émetteur émet une séquence de symboles connus par le récepteur. Ce procédé est appelé apprentissage (figure II.2). Après estimation des paramètres, l'égaliseur est construit et l'égalisation du signal peut commencer [20]. Dans ce qui suit, nous allons nous pencher particulièrement sur les techniques d'égalisation avec apprentissage.

### II.4.1. Egalisation adaptative

L'égalisation adaptative comporte le changement des paramètres du filtre (coefficients) en fonction du temps pour s'adapter aux changements du signal. Pendant les dernières trois décennies, les processeurs de traitement de signal numérique ont fait de grandes avancées dans la rapidité et la miniaturisation.

Par conséquent, les algorithmes de filtrage adaptatif en temps réel deviennent rapidement pratiques et essentiels pour le futur des communications.



**Figure II.2.** Egalisation avec apprentissage

L'égalisation adaptative opère en trois modes :

- Annulation d'écho.
- Egalisation de canal.
- Suppression de bruit large bande / bande étroite.

Un filtre adaptatif est constitué de deux parties (figure II.3) :

- Un filtre numérique à coefficients ajustables de nature FIR ou IIR (Wiener, Kalman ...etc.),
- Un algorithme de modification de ces coefficients ajustables basé sur un critère d'optimisation [22].

#### II.4.1.1. Filtrage numérique

Les filtres sont développés à partir de concepts temporels et non fréquentiels et sont conçus pour minimiser l'erreur quadratique moyenne entre leur sortie et une sortie désirée. Ils sont dits optimums au sens du critère de l'erreur quadratique moyenne. Il est à noter que les coefficients des filtres sont liés à la fonction d'auto corrélation du signal d'entrée et à l'inter-corrélation entre les signaux d'entrée et de sortie désirée [23, 24].

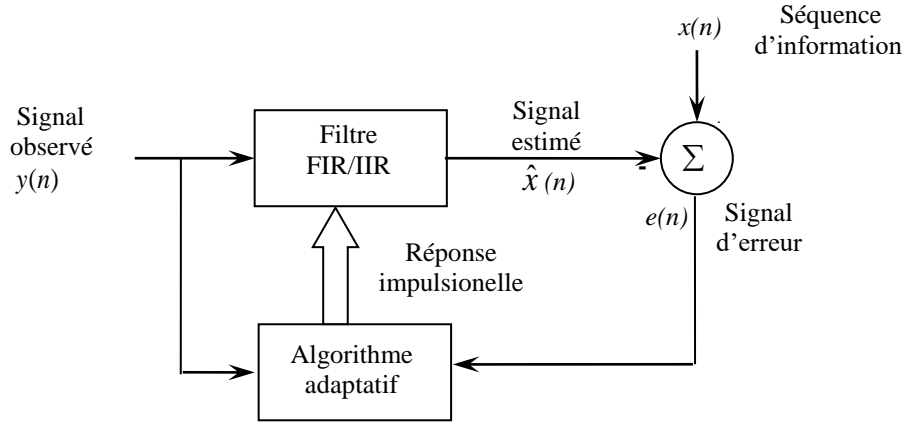


Figure II.3. Schéma d'un système de filtrage adaptatif

La figure II.4 illustre un problème courant d'estimation linéaire.  $x(n)$  correspond au signal qui nous intéresse mais n'est pas directement accessible. Seul  $y(n)$  l'est, et  $y(n)$  est obtenu après passage de  $x(n)$  dans un système linéaire suivi de l'addition d'un bruit.

Le problème qui se pose est comment retrouver  $x(n)$  à partir de  $y(n)$ . Une solution consiste à filtrer  $y(n)$  de telle sorte que la sortie  $\hat{x}(n)$  soit la plus proche possible de  $x(n)$ . On peut mesurer la qualité de l'estimation par  $e(n)$  défini par :

$$e(n) = x(n) - \hat{x}(n) \tag{II.1}$$

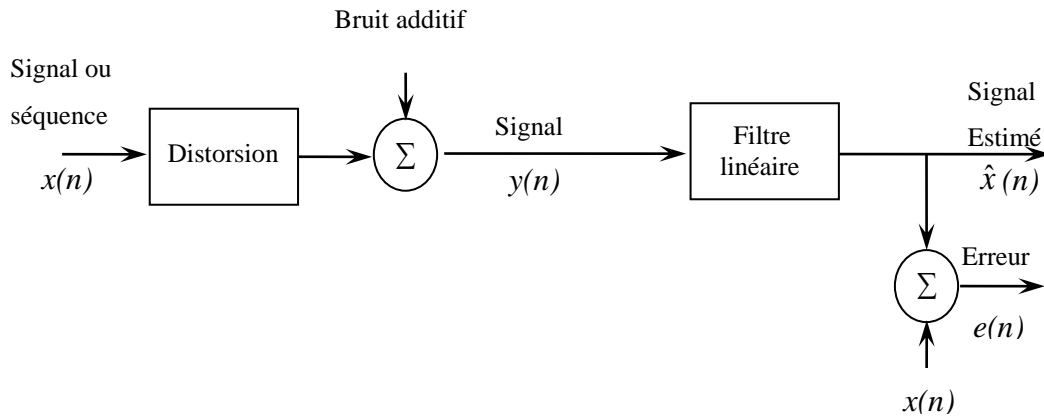


Figure II.4. Problème d'estimation linéaire



Evidemment, plus  $e(n)$  sera faible, plus l'estimation sera bonne. On cherche donc un filtre qui minimisera l'erreur. Il est pratique de chercher à minimiser  $e^2(n)$  car c'est une fonction quadratique facilement dérivable. Par ailleurs, étant donné que les signaux intéressants sont aléatoires, la fonction coût qui sera à minimiser est l'erreur quadratique moyenne MSE (Mean Square Error) définie par :

$$\xi(n) = E(e^2(n)) \quad (\text{II.2})$$

### II.4.1.2. Types d'algorithmes adaptatifs

Les 31 algorithmes représentés dans le tableau II.1 incluent les gradients et les variantes de l'algorithme LMS ; les méthodes des moindres carrés récursives, la racine carrée conventionnelle, Trellis, et les formes des filtres rapides et transversales ; le domaine de fréquence, le domaine transformé, les approches sous bande et les algorithmes de projection rapides [25].

La conception de la fonctionnalité adaptative d'un filtre commence par des spécifications avec lesquelles les algorithmes sont inclus dans la mise à jour des coefficients. Une taxonomie des algorithmes de filtrage adaptatif a été développée suivant le tableau II.1. Le côté gauche contient les algorithmes du gradient stochastique et les méthodes relatives, tandis que le côté droit contient les méthodes déterministes (projection et moindres carrés).

Les liens entre les méthodes indiquent des similitudes entre les paires d'algorithmes soit en termes de structure d'exécution soit en fonction du coût. Cette taxonomie a un certain nombre de points intéressants :

- Les algorithmes les plus populaires et qui sont employés couramment sont : LMS, RLS, et NLMS. Ils sont situés au centre et ont de nombreux liens aux méthodes relatives. La plupart des algorithmes particuliers tels que le FTF et le FAP incluent le LMS et deviennent hybrides.
- Il y a deux classes distinctes des algorithmes adaptatifs (méthodes stochastiques et déterministes) avec relativement peu de liens entre

elles. Dans ces algorithmes les classes sont des groupes qui sont semblables dans l'implémentation ou dans les principes à la base de leurs dérivations.

- On peut utiliser le regroupement donné par cette taxonomie pour différencier entre les différents algorithmes présentés [25].

Acronym	Algorithm	Acronym	Algorithm
<i>Simple Updates</i>		<i>Delayed Updates</i>	
LMS	Least-mean-square	DLMS	Delayed LMS
SE	Sign-error	FXLMS	Filtered-X LMS
SD	Sign-data	ADJLMS	Adjoint LMS
SS	Sign-sign	<i>Projections Methods</i>	
<i>Block and Frequency Domain Methods</i>		NLMS	Normalized LMS
BLMS	Block LMS	AP	Affine projection $O(N^3)$
BLMSFFT	Block LMS (FFT)	AP2	Affine projection $O(N^2)$
FDAF	Frequency-domain adaptive filter	FAP	Fast affine projection
UFDAF	Unconstrained FDAF	BAP	Block affine projection
PBFDAF	Partitioned-block FDAF	<i>Conventional Least-Squares Methods</i>	
PBUFDAF	Partitioned-block unconstrained FDAF	RLS	Recursive least-squares
<i>Transform Domain and Sub-band Methods</i>		SWRLS	Sliding-window RLS
TDAFDFT	Transform-domain adaptive filter (DFT)	<i>Square-Root Least-Squares Methods</i>	
TDAFDCT	Transform-domain adaptive filter (DCT)	QRDRLS	QR-decomposition RLS
SBAF	Sub-band adaptive filter	HRLS	Householder RLS
<i>Lattice Structures</i>		HSWRLS	Householder sliding-window RLS
GAL	Gradient adaptive lattice	<i>Fast transversal filter</i>	
LSL	Least squares lattice	FTF	Fast transversal filter
QRDLISL	QR-decomposition least-squares lattice	SWFTF	Sliding-window fast transversal filter

**Tableau.II.1.** Algorithmes adaptatifs à travers les filtres adaptatifs.

### II.4.1.3. Choix de l'algorithme

Quand les fonctions d'auto et d'inter-corrélation ne sont pas connues (cas le plus courant), on va alors approcher le filtre optimal en utilisant une boucle de retour et un algorithme de minimisation : c'est ce qu'on appelle le filtrage adaptatif (figure II.3). Dans ce cas, on remplacera la connaissance des fonctions

de corrélation par une phase d'apprentissage permettant de modifier itérativement la réponse impulsionnelle du filtre.

L'algorithme doit se préoccuper des facteurs suivants [26] :

- La rapidité de convergence qui sera le nombre d'itérations nécessaires pour converger « assez près » de la solution optimale.
- La mesure de cette "proximité" entre cette solution optimale et la solution obtenue.
- La capacité de poursuite (tracking) des variations (non stationnarités) du processus.
- La robustesse vis-à-vis du bruit.
- La complexité.
- La structure (modularité, parallélisme, ...).
- Les propriétés numériques (stabilité et précision).

Nous ne nous intéresserons dans le cadre de notre travail à tous ces critères de choix, ce qui nous mène aux deux algorithmes les plus utilisés dans le domaine du traitement de signal et le filtrage adaptatif qui sont le LMS et le RLS.

#### II.4.1.3.1. Algorithme LMS

L'algorithme LMS (Least Mean Squares) est un choix populaire dans beaucoup d'applications exigeant le filtrage adaptatif. Deux raisons principales de sa popularité sont : simplicité et complexité informatique réduite. En outre, il y a plusieurs variantes de l'algorithme qui peuvent être employées spécifiquement afin de résoudre différents types de problèmes qui sont inhérents à certaines applications.

La version de base du LMS est un cas spécial du filtre adaptatif du gradient descendant (steepest descent) bien connu. Le but de cette technique est de réduire au minimum une fonction de coût quadratique en mettant à jour itérativement des poids de sorte qu'ils convergent à la solution optimale.

De la méthode de gradient descendant, le vecteur de poids d'égalisation est donné par l'équation suivante :

$$h(n+1) = h(n) + 1/2\mu \left[ -\nabla(E(e^2(n))) \right] \quad (\text{II.3})$$

où :

$\mu$  est un paramètre crucial affectant la stabilité et le taux de convergence de l'algorithme LMS. Il représente le pas de descente de l'algorithme.

$e^2(n)$  est l'erreur quadratique moyenne entre la sortie  $\hat{x}(n)$  et le signal de référence  $x(n)$  ; elle est donnée par la formule suivante :

$$e^2(n) = [x^*(n) - h^T y(n)]^2 \quad (\text{II.4})$$

où :

$$e(n) = x(n) - \hat{x}(n)$$

et

$$\hat{x}(n) = h^T y(n) \Leftrightarrow \hat{x}(n) = y^T(n)h$$

Le vecteur gradient est donné par :

$$\nabla = -2\Phi_{yx} + 2\Phi_{yy}h \quad (\text{II.5})$$

Dans la méthode du gradient descendant, le plus gros problème est le calcul impliqué dans la recherche des valeurs  $\Phi_{yy}$  et  $\Phi_{yx}$  des matrices en temps réel. Pour y remédier, l'algorithme LMS utilise les valeurs instantanées des matrices de covariance  $\Phi_{yy}$  et  $\Phi_{yx}$  au lieu de leurs valeurs réelles, c'est-à-dire :

$$\Phi_{yy} = E[y(n)y^T(n)] \quad (\text{II.6})$$

$$\Phi_{yx} = E[y(n)x^*(n)] \quad (\text{II.7})$$

Par conséquent, la mise à jour du vecteur de poids d'égalisation peut être donnée par l'équation suivante :

$$\begin{aligned} h(n+1) &= h(n) + \mu.y(n)[x^*(n) - y^T(n)h(n)] \\ &= h(n) + \mu y(n)e(n)^* \end{aligned} \quad (\text{II.8})$$

L'algorithme LMS est engagé à démarrer avec une valeur arbitraire  $h(0)$  pour le vecteur de poids à  $n = 0$ . Les rectifications successives du vecteur de poids conduisent finalement à la valeur minimale de l'erreur quadratique moyenne.

**Convergence et stabilité de l'algorithme LMS :** L'algorithme LMS engagé avec certaines valeurs arbitraires pour le poids est perçu comme vecteur de convergence : Si  $\mu$  est choisie très faible alors l'algorithme converge très lentement. Une grande valeur de  $\mu$  peut conduire à une accélération de convergence, mais peut-être moins stable autour de la valeur minimale. Habituellement  $\mu$  est choisie dans la marge [27] :

$$0 < \mu < \frac{2}{\lambda_{\max}} \quad (\text{II.9})$$

où  $\lambda_{\max}$  représente la valeur propre maximale de la matrice d'auto-corrélation  $\Phi_{yy}$ .

La convergence de l'algorithme est inversement proportionnelle à la propagation des valeurs propres de la matrice d'auto corrélation  $\Phi_{yy}$ . Pour des valeurs propres de  $\Phi_{yy}$  qui sont très répandues, la convergence peut être lente.

#### II.4.1.3.2. Algorithme RLS

Sachant que les propriétés statistiques nous sont inconnues, on ne va pas chercher à minimiser  $E[e^2(n)]$  mais une somme finie d'erreur donnée au carré par :

$$\zeta = \sum_{k=0}^n (x(k) - \hat{x}(k))^2 \quad (\text{II.10})$$

Quand cette fonction de coût est minimisée en utilisant une réponse impulsionnelle  $h(n)$  associée à  $\hat{x}(n)$ , on obtient l'estimée des moindres carrés.

La réponse impulsionnelle est donc fonction des échantillons disponibles et non pas d'une moyenne statistique générale. Elle est donnée par la relation :

$$R_{yy}(n)h(n) = r_{yx}(n) \quad (\text{II.11})$$

où :

$$R_{yy}(n) = \sum_{k=0}^n y(k)y^T(k) \quad (\text{II.12})$$

et

$$R_{yx}(n) = \sum_{k=0}^n y(k)x(k) \quad (\text{II.13})$$

La réponse impulsionnelle du filtre est donc à modifier à chaque nouvel échantillon. Pour limiter la taille du calcul, on passe par une équation récursive :

$$h(n) = h(n-1) + k(n)e(n) \quad (\text{II.14})$$

où le vecteur du gain :

$$k(n) = \frac{R_{yy}^{-1}(n-1)y(n)}{(I + y^T(n)R_{yy}^{-1}(n-1)y(n))} \quad (\text{II.15})$$

$$e(n) = x(n) - h^T(n-1)y(n) \quad (\text{II.16})$$

et

$$R_{yy}^{-1}(n) = R_{yy}^{-1}(n-1) - k(n)y^T(n)R_{yy}^{-1}(n-1) \quad (\text{II.17})$$

$$R_{yy}^{-1}(n) = R_{yy}^{-1}(n-1) - \frac{R_{yy}^{-1}(n-1)y(n)y^T(n)R_{yy}^{-1}(n-1)}{(I + y^T(n)R_{yy}^{-1}(n-1)y(n))} \quad (\text{II.18})$$

Ces équations représentent l'algorithme RLS [28, 29].

## II.5. Modèles de canal de propagation

La couche physique d'un système de communication radio représente la limitation cruciale de la qualité de son réseau. Cela dépend de la bande passante, du débit de données, de l'atténuation et des interférences.

L'amélioration de la couche physique d'un système de communication radio signifie le développement de meilleurs émetteurs et récepteurs capables de prédire et d'annihiler les changements d'état des canaux et les effets indésirables. Différents modèles et distributions ont été mathématiquement développés pour représenter un canal. Ils peuvent être scindés en deux catégories : canal avec ligne de vue (LOS), et canal avec non-ligne de vue (NLOS). La modélisation d'un

canal NLOS repose sur un calcul de traitement physique (réflexion, diffraction, diffusion) affectant un signal pendant la transmission. Avec la puissance du signal considéré, le processus est appelé canal d'évanouissement par trajets multiples. Nakagami-m représente une distribution généralisée pouvant être appliquée en tant que canal LOS ou NLOS [15, 30]. Les distributions Rice et Rayleigh sont des cas particuliers de Nakagami-m et qui peuvent être considérés comme des canaux LOS et NLOS, respectivement. Elles sont principalement utilisées pour modéliser ces canaux. Dans ce travail, le canal d'évanouissement de Rayleigh est utilisé en raison de ses bonnes et équitables approximations de l'évanouissement par trajets multiples dans la vie réelle. La génération du modèle sera décrite dans le chapitre IV.

## **II.6. Conclusion**

Lors d'une transmission de données de l'émetteur au récepteur, le canal de transmission peut avoir plusieurs effets sur le signal transmis. Le canal est souvent symbolisé incluant une source de bruit additif mais il peut aussi atténuer fortement certaines fréquences porteuses ; on parle alors de fading sélectif. Le canal peut aussi avoir pour effet de "mélanger" les symboles transmis ; on parle alors d'interférences entre symboles.

L'égalisation adaptative consiste à pallier le mieux possible les déformations causées par le canal de transmission au signal utile grâce à l'utilisation de filtre qui changent de coefficients en temps réel.

Nous avons décrit les structures de certains égaliseurs en mettant en relief leurs algorithmes d'adaptation. Plus précisément, les algorithmes LMS et RLS sont explicités.

**Chapitre III :**  
**Réseaux de Neurones**  
**Artificiels**



# Chapitre III :

## Réseaux de Neurones Artificiels

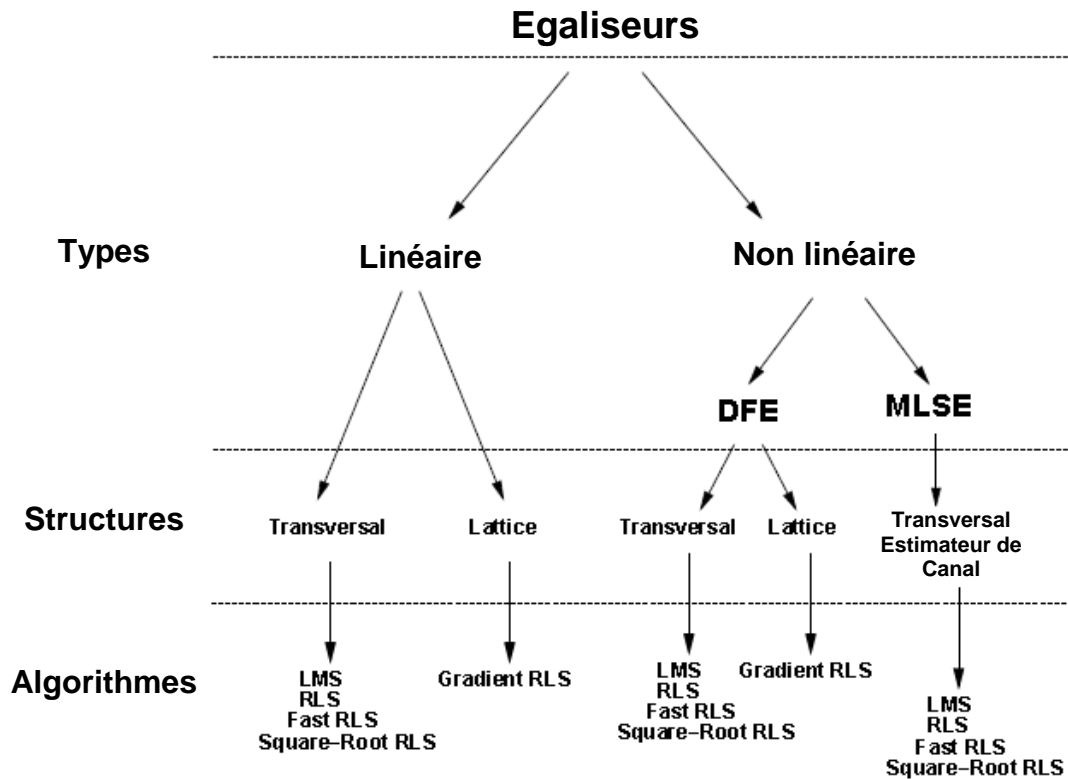
### III.1. Introduction

Les techniques d'égalisations peuvent être classées en deux ensembles (figure III.1) : égaliseurs linéaires et égaliseurs non linéaires [31]. Les techniques linéaires sont généralement les plus simples à mettre en œuvre et à comprendre conceptuellement. Cependant, les techniques d'égalisation linéaire ont des performances limitées face à des canaux fortement dispersifs ou non linéaires, et ne sont donc pas utilisées dans la plupart des applications sans fil ; ce qui a encouragé le développement de nouvelles techniques non linéaires. La figure III.1 résume les différents types d'égaliseur, ainsi que leurs structures et algorithmes de mise à jour [15].

### III.2. Egalisation linéaire

L'égalisation linéaire est une technique commune pour annuler l'effet ISI et MAI et qui consiste à adapter les coefficients d'un filtre transversal ou FIR jusqu'à ce qu'une fonction coût soit minimisée. Pour que le problème soit facile à formuler mathématiquement, la fonction coût doit être différentiable avec le respect des coefficients du filtre. Le choix le plus utilisé pour cette fonction coût est l'erreur quadratique moyenne (MSE).

Les algorithmes populaires employés pour cette égalisation sont le LMS et le RLS décrits précédemment.



*Figure III.1. Un groupement possible des techniques d'égalisations [15].*

### III.3. Egalisation non linéaire

Dans beaucoup de situations, le canal peut avoir des distorsions non linéaires. Si la distorsion est sévère, les égaliseurs linéaires auront de pauvres performances ; dans ce cas les égaliseurs non linéaires doivent être employés mais, en général, la solution mathématique pour ce modèle est compliquée [31].


Parmi les techniques d'égalisation non linéaire, l'égalisation à rétroaction de décision (DFE) est la plus courante, car elle est relativement simple à mettre en œuvre et ne souffre pas de l'influence du bruit. Cependant, sur les canaux avec un faible rapport signal / bruit, la DFE souffre d'une propagation d'erreur lorsque les bits sont décodés en erreur, ce qui entraîne de mauvaises performances. La technique d'égalisation optimale à utiliser est l'estimation de la séquence du maximum de vraisemblance (MLSE). Malheureusement, la complexité de cette

technique croît de manière exponentielle avec la longueur de la mémoire, et n'est donc pas pratique sur la plupart des cas. Par ailleurs, les performances de la MLSE sont souvent utilisées comme référence de performance pour d'autres techniques d'égalisation [15].

Une alternative au problème d'égalisation a été trouvée dans les réseaux de neurones artificiels. Les réseaux comme le Multilayer Perceptrons (MLP) et le Radial Basis Function (RBF) ont été appliqués à l'égalisation du canal. Le problème d'égalisation est reformulé comme un problème de classification : les données émises sont considérées comme des symboles qui appartiennent à un ensemble fini. Le réseau agit comme un classificateur qui détermine quelle est la nature du symbole émis.

### III.4. Les réseaux de neurones artificiels (ANN)

Inspirés des neurones biologiques, les ANN (Artificiel Neural Networks) traitent l'information qu'ils reçoivent d'une manière analogue aux neurones du cerveau. Ils sont constitués de plusieurs éléments processeurs dits neurones artificiels (figure III.2) reliés les uns aux autres par un réseau complexe.



**Figure III.2.** Structure d'un réseau de neurones

La sortie de chaque neurone peut être reliée en entrée à plusieurs autres neurones. Chaque neurone effectue une somme pondérée des signaux d'entrée

modulés par une fonction dite activation (une fonction non linéaire) et génère une sortie qui sera appliquée aux autres neurones via des connexions pondérées. Avec cette simple structure et en choisissant un nombre approprié de neurones, ces réseaux sont capables d'approximer n'importe quelle fonction continue avec une certaine précision.

### **III.4.1. Architecture et fonctionnement**

Le facteur déterminant le type d'un réseau de neurones est la nature des connexions entre ses cellules. Selon ce paramètre, les réseaux de neurones peuvent être classés en deux principales catégories suivant la structure des connexions : les réseaux non récurrents (statiques) et les réseaux récurrents (dynamiques). Les réseaux non récurrents ont une structure hiérarchique qui consiste en plusieurs couches : une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie.

La sortie pour chaque neurone dépend uniquement des sorties des neurones précédents dont les signaux circulent de la couche d'entrée à la couche de sortie dans une seule direction. Pour les réseaux dynamiques, plusieurs neurones sont interconnectés pour organiser le réseau où la circulation de l'information est bidirectionnelle. Dans la littérature, on cite le modèle de Hopfield [7].










### **III.4.2. Fonctions de transfert**

Le tableau III.1 représente les différentes fonctions de transfert qui peuvent être utilisées comme fonction d'activation d'un neurone. Les fonctions de transfert les plus utilisées sont les fonctions seuil, linéaire, sigmoïde et tangente hyperbolique [32].

### **III.4.3. Entraînement des réseaux de neurones**

L'application des réseaux de neurones comprend typiquement deux phases : une phase d'apprentissage et une phase d'opération. L'apprentissage est un

processus à travers lequel les paramètres (les poids de connexions) du réseau sont ajustés pour refléter l'information contenue dans la structure du réseau. Utilisant les valeurs d'entrée/sorties désirées, le réseau ajuste ses poids en se basant sur l'erreur de la sortie calculée. Une fois le réseau est entraîné, il représente une base de connaissance statique qui peut être appelée durant la phase d'opération.

<i>Fonction</i>	<i>Relation d'entrée / sortie</i>	<i>Symbole</i>
<i>Seuil</i>	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$	
<i>Seuil symétrique</i>	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$	
<i>Linéaire</i>	$a = n$	
<i>Linéaire saturée</i>	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$	
<i>Linéaire saturée Symétrique</i>	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$	
<i>Linéaire positive</i>	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$	
<i>Sigmoïde</i>	$a = \frac{1}{1 + e^{-n}}$	
<i>Tangente hyperbolique</i>	$a = \frac{e^{-n} - e^n}{e^{-n} + e^n}$	
<i>Compétitive</i>	$a = 1$ si $n$ maximum $a = 0$ autrement	

**Tableau III.1.** Fonctions de transferts d'un neurone.

L'algorithme de la rétropropagation est la méthode la plus utilisée pour l'entraînement des réseaux de neurones [33]. Il consiste à calculer les dérivées partielles d'une entité (norme d'erreur) par rapport aux paramètres du réseau (poids de connexions) en minimisant une fonction coût. Bien que cet algorithme

soit le plus utilisé, il possède deux problèmes : une convergence lente et aussi l'estimation des paramètres risque de tomber dans un minimum local du critère d'optimisation. Pour contourner ces problèmes, plusieurs techniques d'apprentissage ont été adoptées dans la littérature telles que la méthode du moindre carré récurrent, le filtre de Kalman, les algorithmes génétiques, ...etc.

### III.4.4. MultiLayer Perceptron (MLP)

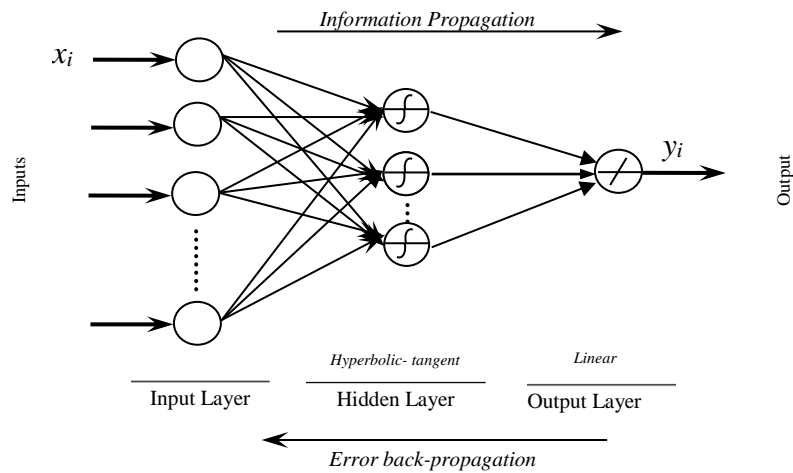
Le perceptron multicouche est un des réseaux de neurones les plus utilisés pour des problèmes d'approximation, de classification et de prédiction. Il est habituellement constitué de deux ou trois couches de neurones totalement connectés.

Le réseau perceptron multicouches est dans la famille générale des réseaux à propagation vers l'avant (Feedforward propagation), c'est-à-dire qu'en mode normal d'utilisation, l'information se propage dans un sens unique, des entrées vers les sorties sans aucune rétroaction (figure III.3). Son apprentissage est de type supervisé par correction des erreurs. Dans ce cas uniquement, le signal d'erreur est rétro-propagé vers les entrées pour mettre à jour les poids des neurones [32].

Le perceptron simple est la base du réseau perceptron multicouches. Un simple perceptron est un perceptron à une seule couche de neurones dont les fonctions d'activation sont illustrées dans le tableau III.1. Les différentes règles d'apprentissage pour la correction des erreurs utilisées pour le MLP sont la règle LMS (Least Mean Square), l'algorithme de rétropropagation (back-propagation), la méthode de Newton et la méthode du gradient conjugué. Dans notre travail nous nous basons sur l'algorithme de rétropropagation.

#### III.4.4.1. Rétropropagation du gradient

L'algorithme BP (*back propagation*), qui est en fait une version généralisée du LMS mais basé sur l'algorithme de la descente du gradient, est appliqué à des structures non linéaires. Son apprentissage est le même que l'algorithme de la descente du gradient.



**Figure III.3.** Structure du réseau MLP

#### III.4.4.1.1. Etapes d'apprentissage

L'apprentissage consiste à ajuster les coefficients synaptiques (coefficients de pondérations) pour que les sorties du réseau soient les plus proches possibles des sorties de l'ensemble d'entraînement. Donc il faut spécifier une règle d'apprentissage afin de l'utiliser pour l'adaptation de ces paramètres. On utilise pour cela la méthode de la rétropropagation qui se divise en deux étapes :

**Une étape de propagation** : qui consiste à présenter une configuration d'entrée au réseau, puis à propager cette entrée de proche en proche de la couche d'entrée à la couche de sortie en passant par les couches cachées.

**Une étape de rétropropagation** : qui consiste, après le processus de propagation, à minimiser l'erreur commise sur l'ensemble des exemples présentés, erreur considérée comme une fonction des poids synaptiques. Cette erreur représente la somme des différences au carré entre les réponses calculées et celles désirées pour tous les exemples contenus dans l'ensemble d'apprentissage. Simplement dit, la procédure de la rétropropagation repose sur l'idée de rétropropager vers les couches internes (cachées) l'erreur commise en sortie, d'où la méthode tire son nom.

Il est indispensable, avant d'entamer le principe de la rétropropagation, de définir une topologie du réseau, et les relations qui relient les entrées et les sorties d'une part, les entrées et les poids d'autre part [33].

#### III.4.4.1.2. Principe de la rétropropagation

La rétropropagation est basée sur l'adaptation des coefficients synaptiques afin de minimiser une fonction de coût (performances) donnée par :

$$j(w) = \sum_{p=1}^T j_p(w) \quad (\text{III.1})$$

$$j_p(w) = \frac{1}{2} \sum_{i=1}^n |y^d(t) - y(t)|^2 \quad (\text{III.2})$$

où

$y^d(t)$  : sortie désirée du réseau.

$y(t)$  : sortie du réseau.

$T$  : nombre d'exemples ou la longueur de l'ensemble d'entraînement.

La méthode du gradient consiste à modifier d'une quantité proportionnelle les coefficients synaptiques aux taux de changement de l'écart en fonction du changement de ce même coefficient.

On commence l'entraînement par un choix aléatoire des valeurs des poids en présentant l'entrée et la sortie désirée correspondante. A la sortie du réseau, l'erreur commise et le gradient de l'erreur par rapport à tous les poids sont calculés, ensuite les poids sont ajustés. Cette procédure est répétée jusqu'à ce que les sorties du réseau soient suffisamment proches (avec précision appropriée) des sorties désirées. A ce niveau, l'apprentissage est achevé en donnant un réseau capable d'accomplir la tâche prévue.

#### III.4.4.2. Equations du réseau

Les états des différents neurones d'un réseau multicouches à  $L$  couches (couches cachées et couches de sorties) ayant  $n$  entrées et  $m$  sorties sont donnés par les équations suivantes :



$$u_i^k(t) = f^k(p_i^k(t)) \quad (\text{III.3})$$

$$p_i^k(t) = \sum_{j=0}^{N-1} w_{ij}^k u_j^k(t) \quad (\text{III.4})$$

où :

$$i = 1, 2, \dots, N_k$$

$$k = 1, 2, \dots, L$$

$N_k$  : nombre de neurones dans la  $k^{\text{ème}}$  couche.

$L$  : nombre total de couches.

$u_i^k(t)$  : sortie du neurone  $i$  de la  $k^{\text{ème}}$  couche.

$p_i^k(t)$  : potentiel somatique du neurone  $i$  de la  $k^{\text{ème}}$  couche.

$w_{ij}^k$  : coefficient synaptique (poids) de la  $j^{\text{ème}}$  entrée du neurone  $i$  de la couche  $k$ .

$$u_0^k(t) = 1 ; k = 1, 2, \dots, L \quad (\text{III.5})$$

$$u_0^k(t) = x_i(t) ; i = 1, 2, \dots, n \quad (\text{III.6})$$

$$u_0^k(t) = y_i(t) ; i = 1, 2, \dots, m \quad (\text{III.7})$$

où

$x_i(t)$  : entrées du réseau.

$y_i(t)$  : sorties du réseau.

$f(x)$  : fonction d'activation.

### III.4.4.3. Adaptation des poids

L'adaptation des poids (ajustement, mise à jour des coefficients synaptiques), se fait en se basant essentiellement sur la formule itérative suivante.

$$w_{ij}^k(n+1) = w_{ij}^k - \Delta w_{ij}^k \quad (\text{III.8})$$

$$\Delta w_{ij}^k(n) = \mu \frac{\partial j(w)}{\partial w_{ij}^k(n)} \quad (\text{III.9})$$

où :

$n$  : numéro d'itération.

$\mu$  : pas d'apprentissage.

Il est à noter que le pas d'apprentissage  $\mu$  influe sur la vitesse de convergence  $\frac{\partial j(w)}{\partial w_{ij}^k(n)}$  ; sa valeur est généralement choisie en respectant un certain compromis entre la vitesse de convergence et la précision des résultats.

La dérivée partielle de la fonction coût par rapport aux poids  $w_{ij}^k$  représente la vitesse de variation de l'erreur en fonction de la vitesse de variation des poids. Sur tout l'ensemble d'entraînement on a :

$$\Delta w_{ij}^k(n) = \mu \sum_{p=1}^T \frac{\partial j_p(w)}{\partial w_{ij}^k(n)} \quad (\text{III.10})$$

Pour permettre d'implémenter l'algorithme, une expression pour la dérivée partielle de  $j(w)$  par rapport à chaque poids du réseau pour un choix arbitraire d'une couche  $k$  est donnée par la relation (III.11).

$$\frac{\partial j_p(w)}{\partial w_{ij}^k} = \frac{\partial j_p(w) \partial u_j^k(t)}{\partial u_j^k(t) \partial w_{ij}^k} \quad (\text{III.11})$$

$\frac{\partial j_p(w)}{\partial u(t)}$  : représente la sensibilité de  $j_p(w)$  par rapport à  $y(t)$ .

Pour la couche de sortie, la sensibilité est donnée par :

$$\frac{\partial j_p(w)}{\partial u(t)} = y_i^L(t) - y_i^d(t) \quad (\text{III.12})$$

Cette expression est appelée erreur de sortie.

Pour les couches cachées :

$$\frac{\partial j_p(w)}{\partial u_i^k(t)} = \sum_{j=1}^{N_{k+1}} \frac{\partial j_p(w)}{\partial u_j^{k+1}(t)} \frac{\partial u_j^{k+1}(t)}{\partial u_i^k(t)} \quad (\text{III.13})$$

Cette expression est appelée erreur de la couche cachée ou erreur équivalente.

L'expression  $\frac{\partial u_j^i(t)}{\partial w_{ij}^k}$  est donnée comme suit :

$$\frac{\partial u_j^i(t)}{\partial w_{ij}^k} = f^k(p_j^k(t) \cdot u_i^{k-1}(t)) \quad (\text{III.14})$$

De même, l'expression (III.11) s'écrit sous la forme :

$$\frac{\partial j_p(w)}{\partial w_{ij}^k} = \frac{\partial j_p(w)}{\partial u_i^k(t)} f^k(p_j^k(t) u_j^{k-1}(t)) \quad (\text{III.15})$$

Les poids du réseau doivent être ajustés après la présentation de toutes les entrées pour minimiser l'erreur totale sur l'ensemble d'entraînement. Cependant, tous les poids peuvent être ajustés après la présentation de chaque entrée ; ceci vient du fait que les corrections sont aussi faibles et la minimisation de  $j(w)$  est une bonne approximation de la minimisation de  $j_p(w)$ . La variation des poids  $\Delta w_{ij}^k(n)$  peut alors s'écrire ainsi :

$$\Delta w_{ij}^k(n) = \mu \frac{\partial j_p(w)}{\partial w_{ij}^k(n)} \quad (\text{III.16})$$

#### III.4.4.4. Problèmes du Back-Propagation

Bien que l'algorithme de rétropropagation soit l'algorithme le plus utilisé pour l'apprentissage supervisé des réseaux statiques multicouches, son implantation se heurte à plusieurs difficultés techniques. On ne trouve aucune méthode permettant d'éclairer certaines ambiguïtés telles que :

- Trouver une architecture appropriée (nombre de couches, nombre de neurones).
- Choisir une taille et une qualité adéquate des exemples d'entraînement.
- Choisir des valeurs initiales satisfaisantes pour les poids et les paramètres d'apprentissage permettant d'accélérer la vitesse de convergence.
- Problème de la convergence vers un minimum local, (qui empêche la convergence et cause l'oscillation de l'erreur).

Pour éviter le problème d'oscillations, des chercheurs ont proposé une modification de la loi d'apprentissage donnée par l'expression III.8, à laquelle ils proposent d'ajouter un terme appelé moment [34] ; donc la loi d'adaptation devient:

$$w_{ij}^k(n+1) = w_{ij}^k(n) - \mu \frac{\partial j_p(w)}{\partial w_{ij}^k(n)} + \alpha [w_{ij}^k(n) - w_{ij}^k(n-1)] \quad (\text{III.17})$$

avec :  $0 \leq \alpha < 1$

### III.4.5. Radial Basis Function (RBF)

L'identification des paramètres du perceptron, appelés poids de connexions, est souvent réalisée par l'utilisation de l'algorithme de rétro propagation basée sur la méthode de la descente du gradient, dont l'objectif est la minimisation de l'erreur d'apprentissage. Cependant, la surface de l'erreur est souvent complexe et présente des caractéristiques peu satisfaisantes pour réaliser une descente du gradient, ce qui crée des inconvénients, tels que : la lenteur de la convergence, la sensibilité aux minima locaux et la difficulté à régler les paramètres d'apprentissage. Un autre type de réseau de neurones très utilisé est le réseau de neurones à fonction radiale de base (RBF). Ce réseau a l'avantage d'être beaucoup plus simple que le perceptron tout en gardant la fameuse propriété d'approximation universelle de fonctions [35]. Les réseaux de neurones RBF sont très exploités dans l'optimisation et la synthèse des systèmes d'égalisation adaptative.

#### III.4.5.1. Types d'apprentissage

En apprentissage, il existe essentiellement deux types d'apprentissage : l'apprentissage supervisé et l'apprentissage non supervisé. Dans la majorité des réseaux neuronaux étudiés, l'apprentissage sera dit supervisé, car on impose des entrées fixes et on cherche à récupérer une sortie connue. On effectue alors la modification des poids pour retrouver cette sortie imposée. Malgré tout, il existe des réseaux à apprentissage non supervisé.

L'apprentissage non supervisé est le seul qui peut expliquer l'apprentissage des systèmes biologiques. Ce processus d'entraînement fait correspondre à une classe donnée de vecteurs d'entrée (qui ont une propriété commune) une sortie particulière ; mais en premier temps, on ne peut pas connaître pour une classe de vecteurs d'entrée, la sortie correspondante. Nous avons plusieurs règles d'apprentissage non supervisées :

- Règle de Hebb
- Règle de Kohonen,
- Règle de Instar,
- Règle de Outstar.

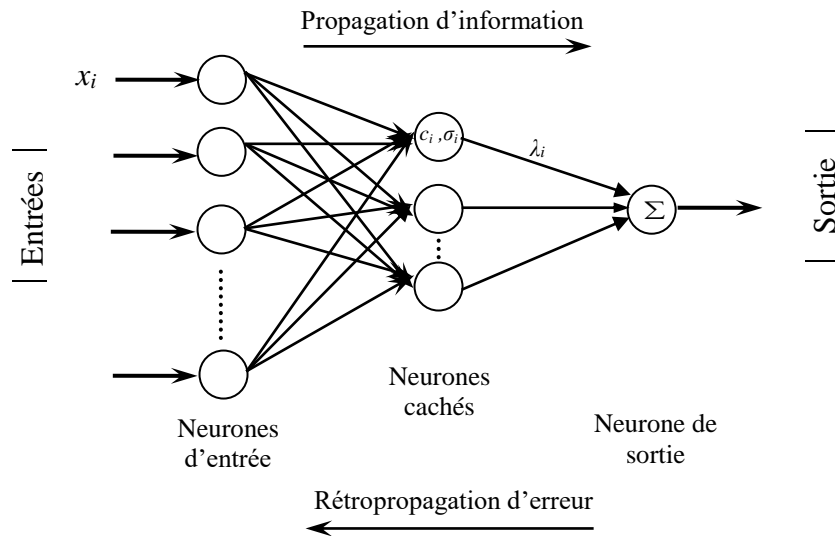
Dans le cas de l'apprentissage supervisé, on cherche à imposer au réseau un fonctionnement donné, en forçant à partir des entrées présentées, les sorties du réseau à prendre des valeurs données en modifiant les poids synaptiques. Le réseau se comporte alors comme un filtre dont les paramètres de transfert sont ajustés à partir des couples (entrée/sortie) présentés. L'adaptation des paramètres du réseau s'effectue à partir d'un algorithme d'optimisation et l'initialisation des poids synaptiques est le plus souvent aléatoire [35].

Dans notre étude, nous avons utilisé :

- Apprentissage supervisé avec le MLP.
- Apprentissage supervisé et non supervisé pour les réseaux à fonction radiale de base (RBF).

#### **III.4.5.2. Apprentissage des réseaux RBF**

Les réseaux RBF peuvent être utilisés dans de vastes applications, puisque, principalement, ils peuvent approximer n'importe quelle fonction et leur entraînement est rapide comparé aux réseaux MLP. Cet apprentissage rapide vient en réalité du fait que les RBF ont seulement deux couches (figure III.4) de paramètres (centroïdes + largeurs et poids) ; et chaque couche peut être déterminée séquentiellement.



**Figure III.4.** Architecture des réseaux RBF

Le MLP est entraîné par des techniques supervisées : les poids sont calculés en minimisant une fonction coût non linéaire. Contrairement au MLP, l'entraînement du réseau RBF peut être divisé en une partie non supervisée et une autre partie linéaire supervisée. Les techniques de mise à jour des paramètres non supervisées sont relativement rapides et à propagation vers l'avant. Encore, la partie supervisée d'apprentissage consiste à résoudre un problème linéaire, ce qui est également rapide, avec le bénéfice additionnel d'éviter le problème de minimums locaux rencontré souvent en utilisant le MLP. La procédure d'entraînement des réseaux RBF peut être décomposée en trois stages [35] :

1. Localiser les centres ( $C_i$ ) des fonctions radiales (gaussiennes),
2. Déterminer leurs largeurs ( $\sigma_i$ ),
3. Calculer les poids du réseau ( $\lambda_j$ ) entre la couche de fonction radiale et la couche de sortie.

### III.4.5.3. Equations du réseau

Le réseau RBF comporte deux couches de neurones. Les cellules de sortie effectuent une combinaison linéaire de fonctions non linéaires fournies par les neurones de la couche cachée. Les méthodes d'approximations qui régissent le réseau sont :

$$F(x) = \sum_{j=1}^M \lambda_j \varphi_j(\|x - c_j\|) + \sum_{i=1}^d a_i x_i \quad (\text{III.18})$$

où :  $M$  est le nombre des centres ( $C_j$ ).

$d$  est la dimension des variables d'entrée.

$\|(\cdot)\|$  dénote la distance euclidienne.

$\varphi_j$  représente la fonction non linéaire du réseau qui est calculée par :

$$\varphi_j(\|x - c_j\|) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma_j^2}\right) \quad (\text{III.19})$$

Les paramètres du réseau sont :  $C_j$ ,  $\sigma_j$  et  $\lambda_j$ . Les centres  $C_j$  sont déterminés et adaptés respectivement en utilisant l'apprentissage non supervisé (competitive learning) avec :

$$d_2(x^i, C^j) = \sqrt{\sum_{k=1}^D (x_k^i - c_k^j)^2} = \|x^i - C^j\| = (x^i - C^j)^T (x^i - C^j) \quad (\text{III.20})$$

$$C^k(t+1) = C^k(t) + \alpha(t)(x^i - C^k) \quad (\text{III.21})$$

où  $\alpha(t)$  est un facteur décroissant d'adaptation de temps,  $0 < \alpha(t) < 1$ .

$\sigma_j$  est adapté grâce à la formule :

$$\sigma = \frac{d_{\max}}{\sqrt{2M}} \quad (\text{III.22})$$

où  $M$  est le nombre de centroïdes.

$d_{\max}$  est la distance maximale entre une paire quelconque de centroïdes.

Une fois les  $C_j$  et  $\sigma = \sigma_j$  sont estimés le problème devient linéaire, il faut donc utiliser la pseudo-inverse pour déterminer les  $\lambda_j$  [36].

### III.5. Conclusion

Plusieurs égaliseurs neuronaux ont été développés. La plupart d'entre eux sont une combinaison entre un filtre linéaire transversal conventionnel (LTF) et un réseau de neurone artificiel (RNA) qui peut être un perceptron multicouche (MLP), un réseau de fonctions radiales de base (RBF) ou autre réseau neuronal.

Dans le chapitre suivant, la conception de deux égaliseurs neuronaux non linéaires MLP et RBF est faite à la lumière de ce chapitre introductif aux réseaux de neurones.



**Chapitre IV :**  
**Optimisation neuronale de**  
**HOM**  
**en réseaux mobiles**

# Chapitre IV :

## Optimisation neuronale de HOM en réseaux mobile

### IV.1. Introduction

Dans ce chapitre, un modèle de simulation est établi, basé sur la génération des symboles modulé en HOM, et transmis sous forme de porteuse OFDM. Ces symboles sont sujet de transmission en canal de Rayleigh à évanouissement plat. A plusieurs degrés de bruit (SNR), la réception des données est faite avec un démodulateur HOM/OFDM. Après, vient le rôle des égaliseurs linéaires (LMS et RLS) et développés (MLP et RBF) pour reconstruire les données reçues en données originales pour chaque modulation M-QAM, et à chaque niveau de bruit SNR. L'efficacité, la robustesse ainsi que la rapidité des modèles sont établies grâce aux critères MSE et BER.

### IV.2. Egalisation ANN en littérature

Parmi les égaliseurs non linéaires, le ANN gagne en importance pour son architecture flexible, son optimisation et son processus d'apprentissage. De nombreuses études sont menées sur l'égalisation ANN des canaux. Les premiers travaux [37, 38] ont montré que les égaliseurs MLP étaient plus efficaces que les égaliseurs transversaux et à rétroaction de décision en termes de performance

BER. Dans [39], il a été prouvé que les variations de l'égaliseur MLP convenaient à une implémentation de faible complexité dans les systèmes de stockage de données et les processus d'égalisation. Un réseau minimal d'attribution de ressources pour RBF est développé, mais uniquement pour les modulations 4-QAM et 2-PAM [40]. Dans [41], différents algorithmes d'apprentissage compétitif pour la détermination des centres RBF sont discutés pour le 4-QAM. D'autres réseaux ont été utilisés dans l'égalisation comme les réseaux de Chebyshev [42], l'ANN de lien fonctionnel de Legendre avec le schéma de modulation à 4 QAM [43], et un ANN basé sur l'algorithme à saut de grenouille modifié [44]. Ces travaux se concentrent sur les problèmes de complexité de calcul, mais n'étudient pas la simplicité d'architecture du réseau. Par conséquent, pour améliorer les performances des égaliseurs dans les canaux non linéaires, de nouvelles structures d'égaliseur sont nécessaires.

### IV.3. Modèle du système

#### IV.3.1. Modèle du canal et génération des symboles

Dans la partie émetteur, 300000 séquences d'un signal aléatoire  $x(n)$  sont générées avec une moyenne nulle et une variance unitaire et sont supposées être indépendantes et réparties identiquement [45].  $x(n)$  est modulé avec HOM et mis en forme avec des porteuses OFDM. Dans M-QAM, nous aurons  $300000/K$  symboles où  $K = \log_2(M)$  est le nombre de bits par symbole.  $M = 16, 64, 128, 256, 512, 1024$ . Après modulation, le signal reçu peut être exprimé par :

$$\tilde{y}(n) = h * x(n) + \eta(n) \quad (\text{IV.1})$$

où  $x(n)$  est le signal émis à travers  $H$  ( $H$  est la fonction de transfert de canal à évanouissement plat de Rayleigh), et  $\eta(n)$  est un bruit gaussien blanc additif complexe généré avec le rapport énergie/bruit  $E_b/N_o = 1 : 28$  dB selon  $M$ .

Le canal à évanouissement plat de Rayleigh  $H$  est considéré comme une modélisation d'un filtre à réponse impulsionnelle finie (FIR) qui peut être obtenu à partir de processus gaussiens complexes aléatoires non corrélés.

Dans la partie récepteur,  $\tilde{y}(n)$  dans l'équation (IV.1) est reconstruit en supprimant le préfixe cyclique, en appliquant la transformée de Fourier rapide et en convertissant les données de flux parallèles en forme sérielle. Après la démodulation OFDM vient la partie délicate de l'égalisation utilisant LMS, RLS, MLP et RBF à différents moments, et en calculant MSE de chacun d'eux pour de différentes modulations M-QAM et un SNR différent. Enfin, les symboles sont démodulés en bits pour calculer le BER. La figure IV.1 représente le modèle pour la prise de décision de symbole pour tous les égaliseurs dans ce chapitre.

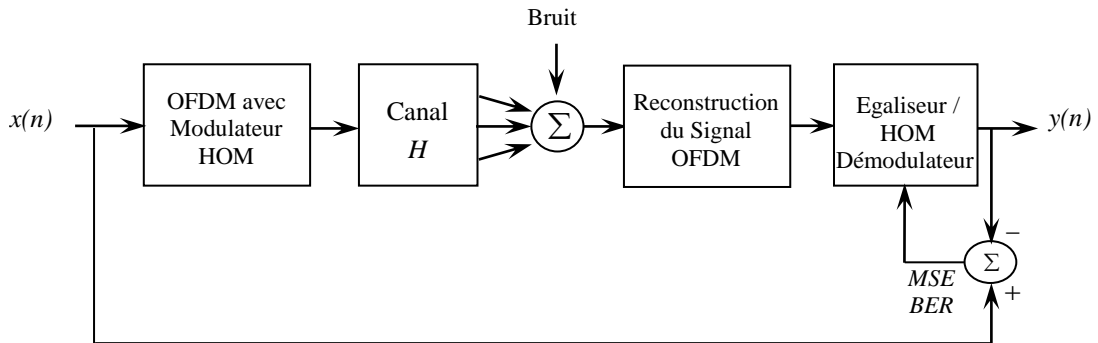



Figure IV.1. Concept utilisé pour l'égalisation du canal.

La génération des porteuses OFDM et ses paramètres, ainsi que les paramètres des distorsions de canal (bruit et multi trajets) sont reportés dans le tableau IV.1.

Parameters	Channel Bandwidth	Number of subcarriers	Subcarrier spacing	Carrier frequency	Channel type	Noise	Number of multipath
Values	10 MHz	128	15 kHz	2.5 GHz	Rayleigh flat-fading	AWGN	3

Tableau IV.1. Paramètres de simulation OFDM.

La figure IV.2 illustre la constellation du signal 1024 QAM généré à la sortie de l'émetteur après transmission via le canal  $H$  avec 31 dB de SNR.



**Figure IV.2.** Constellation distordue de symboles 1024 QAM reçus dans l'entrée du récepteur avec  $SNR = 31$  dB.


### IV.3.2. Paramètres de LMS et RLS

Dans notre modèle, les valeurs du signal et même du canal sont de nature complexe. L'algorithme LMS peut gérer les valeurs complexes et peut être considéré comme un CLMS (LMS Complexe) : un filtre adaptatif linéaire complexe. Ici, le filtre LMS a une longueur de 10 (nombre de coefficient  $w$ ). Sa convergence et son suivi du signal original émis seront traités avec des critères MSE et BER. Il en va de même pour l'algorithme CRLS (RLS Complexe). Les paramètres LMS pour chaque M-QAM sont mentionnés au tableau IV.2. RLS a une longueur de filtre de 10 (nombre de coefficient  $w$ ), et  $\lambda = 0,9$  pour tous les M-QAM.


M-QAM	16	64	128	256	512	1024
$\mu$	0.0039	0.0031	$2 \cdot 10^{-4}$	$4.54 \cdot 10^{-4}$	$3 \cdot 10^{-4}$	$9.99 \cdot 10^{-5}$
$w_n$	10	10	10	10	10	10

**Tableau IV.2.** Paramètres du filtre LMS

La figure IV.3 et la figure IV.4 représentent la convergence des coefficients LMS et RLS. RLS est stable après environ 30 itérations par rapport à LMS (environ 100 itérations) ; il est rapide par rapport aux égaliseurs traditionnels linéaires.



**Figure IV.3.** Convergence des coefficients  $w_n$  du LMS sur 500 itérations pour 16 QAM.



**Figure IV.4.** Convergence des coefficients  $w_n$  du RLS sur 500 itérations pour 16 QAM.

### IV.3.3. Design de l'architecture MLP & RBF

#### IV.3.3.1. Stratégies

Les stratégies les plus utilisées dans l'apprentissage et le design des réseaux ANN sont :

- 1- *Normalisation des entrées* : certains auteurs se penchent sur la normalisation des entrées pour assurer de meilleures performances et une convergence rapide [46, 47].
- 2- *Plus de données, plus de précision* : Des données d'apprentissage plus nombreuses pourraient bien générer un espace de fonctionnalités et empêcher le sur-ajustement.
- 3- *Fonction d'activation* : le bon choix de la fonction d'activation permet un meilleur apprentissage d'une très bonne efficacité. Ce choix présente certains avantages, comme une mise en œuvre simple et un calcul moins coûteux pour former efficacement un réseau de neurones.
- 4- *Choix aléatoire des données* : mélange des données d'apprentissage.
- 5- *Initialisation d'apprentissage* : elle doit être sur une large gamme de donnée ; choisir un taux d'apprentissage élevé s'il n'oscille pas ou ne diverge pas afin de trouver un meilleur minimum global.

#### IV.3.3.2. Valeurs complexes

Dans notre modèle cité au chapitre III, les valeurs du signal et même le canal sont d'une nature complexe. Les algorithmes CLMS et CRLS ont été introduits comme des filtres adaptatifs linéaires complexes ; leurs convergences avec le MSE étaient adressées avec leurs propriétés.

La plus part des réseaux de neurones ordinaires travaillent sur des valeurs réelles et non complexes. Pour remédier à ce problème, on doit concevoir un égaliseur complexe non linéaire.

Deux classes de filtres adaptatifs non linéaires complexes ont été présentées [48] : fully-complex (entièrement complexe) et split-complex (complexe-divisé), les deux avec une approche duelle univariable.

Quand on choisit une fonction non linéaire à la sortie du filtre adaptatif complexe (fonction tangente hyperbolique pour notre égaliseur MLP), on a besoin de choisir entre différentiable (fully-complex) et limite (boundedness – split-complex). Ce choix dépend de l'application : les filtres split-complex sont généralement plus utilisés dans les réseaux de neurones pour la classification et leur apprentissage est simple et rapide ; par contre, les filtres fully-complex constituent plus un choix naturel dans les filtres adaptatifs non linéaires, sauf que leur apprentissage est difficile et ils ont besoin de standardiser les entrées. Ce dernier n'est pas un bon choix vu qu'on cherche la simplicité et la rapidité.

Notre choix s'est porté sur la classe split-complex ; son principe est illustré dans la figure IV.5, où on doit traiter les parties réelles et imaginaires du signal indépendamment. Le problème devient alors réel, puis il suffira de rétablir la forme complexe à la sortie du filtre.

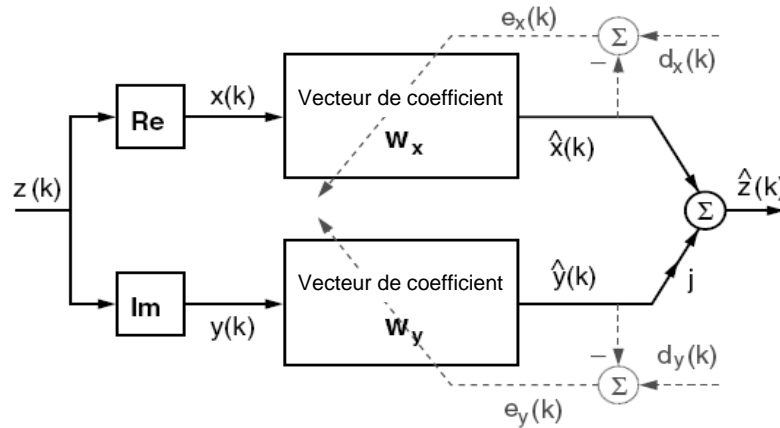


Figure IV.5. Structure d'un filtre adaptatif split-complex (réel & duel univariable)

### IV.3.3.3. MLP

Les principales étapes à suivre pour implémenter MLP et déterminer ses paramètres qui sont le nombre de couches cachées, le nombre de neurones, le nombre d'itérations, le pas  $\mu$  et les poids  $w$ , sont :



*Étape 1 : Choix de l'apprentissage.* L'apprentissage se fera par rétropropagation. La conception et la mise en œuvre de cet algorithme peuvent être résumées comme initialisation de  $w_{ij}^k$ , introduction des vecteurs d'entrée et calcul du MSE, après avoir calculé l'erreur de gradient des poids en utilisant (III.10) et en les ajustant à l'aide des lois itératives (III.8), (III.9) et (III.10). Si les conditions sont remplies (MSE<sub>min</sub> ou nombre maximum d'itérations), l'entraînement est terminé, sinon il faut recommencer avec un autre vecteur d'entrée. Ces points sont démontrés par la figure IV.6.

*Étape 2 : Définir le nombre de couches cachées.*

*Étape 3 : Sélectionner la fonction d'activation.*

*Étape 4 : Déterminer le nombre de neurones dans chaque couche cachée.*

Après les étapes précédentes, le modèle MLP développé est prêt. Les séquences utilisées pendant l'apprentissage ont plusieurs SNR. Après les étapes d'apprentissage, vient la validation et le test de l'égaliseur MLP, et ensuite il sera appliqué sur les séquences déformées.

- **Apprentissage** : pendant l'apprentissage, nous fixons les nombres de neurones dans la couche cachée en changeant graduellement ce nombre et en calculant à chaque fois l'erreur MSE. Le nombre optimal de neurones a le minimum MSE.
- Après avoir défini le nombre optimal de neurones dans notre réseau (10 neurones), nous devrions fixer la valeur de  $\mu$  (taux d'apprentissage). Pour obtenir le meilleur résultat, nous devons également rechercher l'erreur minimale ( $\mu = 0,001$ ).
- **Validation** : Après le paramétrage du paramètre réseau MLP (nombre de neurones et  $\mu$ ) vient la validation, à partir d'une initialisation aléatoire, des poids  $w_n$  des entrées et de sortie calculés pour chaque séquence de l'ensemble des validations pour arriver à leurs valeurs optimales qui donnent le MSE minimum sur l'ensemble entier.

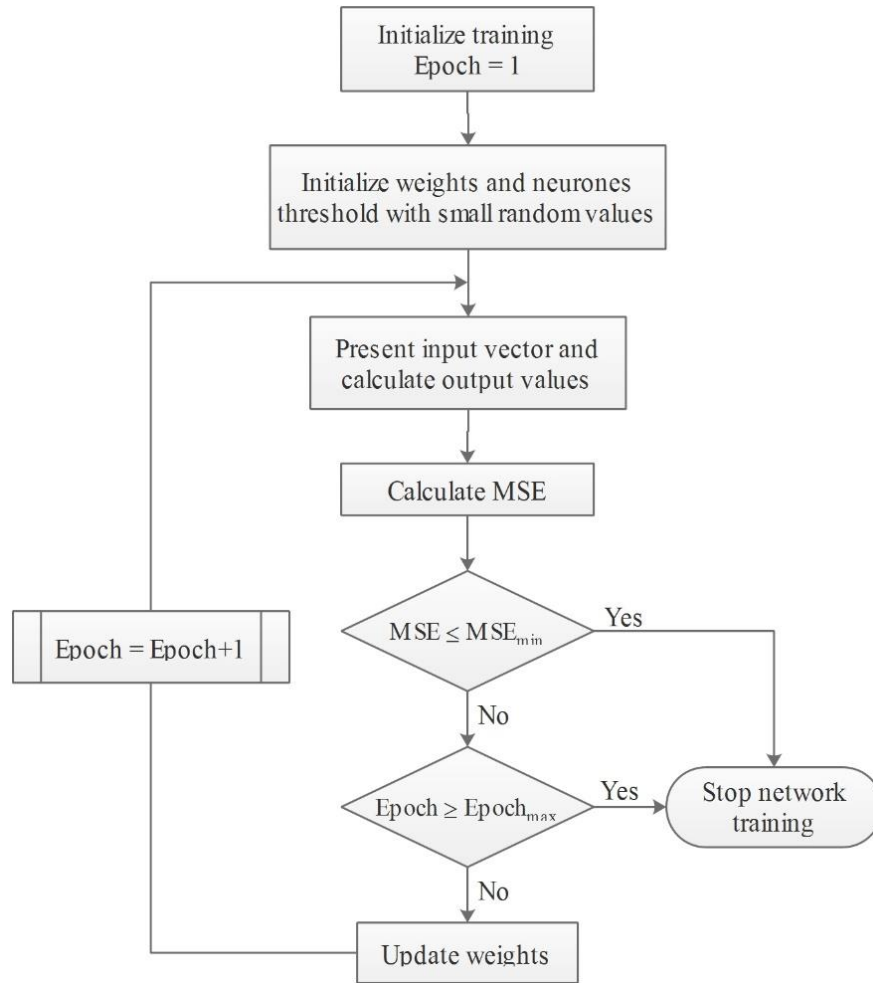




Figure IV.6. Algorithme back-propagation.



(a)



(b)

Figure IV.7. Etape de validation du MLP basée sur le MSE et le nombre d'itérations

(a). 50 itérations (b). 100 itérations.

- Le nombre d'itérations augmente d'une part l'efficacité du réseau, et d'autre part le rend lent ; c'est aussi à travers le MSE que l'on peut choisir un nombre d'itération optimal :  $\text{MSE}(100_{\text{it}}) \approx \frac{1}{2} \text{MSE}(50_{\text{it}})$  (voir figure IV.7). Aucune règle ne définit comment fixer ce nombre, cela dépend des besoins : la célérité ou la précision du résultat.
- **Test** : l'égaliseur MLP doit être testé (voir simulations plus loin).

#### IV.3.3.4. RBF

Ici, le traitement du problème d'égalisation est le même que dans MLP, sauf que la structure de l'égaliseur RBF et les paramètres internes sont différents. Les étapes de mise en œuvre et les stratégies d'apprentissage du réseau RBF sont résumées comme suit :

*Étape 1* : fixer le nombre de neurones dans la couche cachée.

*Étape 2* : la stratégie d'apprentissage traditionnelle est utilisée, c'est-à-dire le calcul séparé basé sur les équations de réseau, comme suit :

- Apprentissage non supervisé pour les centres gaussiens  $C_j$  et largeurs  $\sigma_j$ .
- Apprentissage supervisé pour les connexions de poids  $\lambda_j$ .

Après, nous validons notre réseau et le testons pour les séquences de validation et de test comme avec le MLP.

• **Apprentissage** : En utilisant les séquences d'entrée pour l'apprentissage non supervisé, les centres ( $C_j$ ) sont calculés en utilisant les deux équations (III.20) et (III.21) (calcul de la distance et de l'adaptation des centroïdes). Après avoir fixé les centroïdes, nous devrions définir la valeur sigma ( $\sigma$ ) : largeur de la gaussienne à travers l'évolution de l'erreur MSE. Les largeurs optimales obtenues sont  $\sigma = [0.5, 0.5, 1, 0.5, 1, 1]$  pour  $M = [16, 64, 128, 256, 512, 1024]$ , respectivement. Maintenant, nous changeons le nombre de neurones progressivement ; le nombre optimal est de 40 neurones pour 256, 512 et 1024 QAM et 20 pour le reste de l'ordre de modulation.

- **Validation** : Après fixation des paramètres du réseau RBF (centroïdes, nombre de neurones dans la couche cachée et valeur  $\sigma$ ) vient l'étape de validation ; ici les poids  $\lambda_n$  des neurones de sortie sont calculés pour chaque séquence de l'ensemble de validation. Il est fait à partir d'une initialisation aléatoire pour arriver à leurs meilleures valeurs qui donnent le minimum MSE sur l'ensemble.
- **Test** : l'égaliseur doit être testé (voir simulations plus loin).

## IV.4. Simulation & résultats

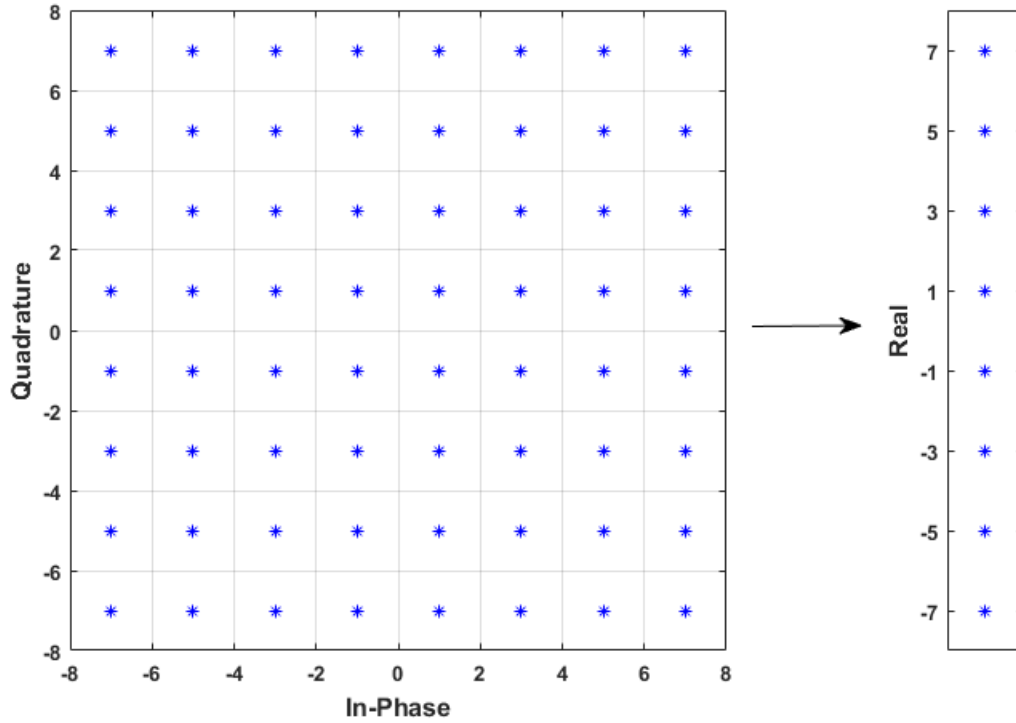
### IV.4.1. Récapitulatif sur les réseaux MLP et RBF

Les égaliseurs ANN fonctionnent avec des valeurs réelles ou complexes. ANN réel a une architecture plus simple et son apprentissage est rapide et n'est pas compliqué par rapport au ANN complexe. Cette simplicité et cette rapidité que nous recherchons sont obtenues en divisant des symboles complexes modulés en parties réelles et imaginaires (figure IV.8) et traités séparément, **l'un après l'autre**. Ensuite, les symboles sont remodelés à la sortie sous une forme complexe. La stratégie utilisée dans l'apprentissage pour les deux égaliseurs neuronaux (MLP & RBF) est que les symboles totaux sont répartis aléatoirement entre apprentissage (70%), validation (15%) et test (15%) où chaque étape est évaluée avec le MSE. Les architectures sont conçues pour être simples pour éviter la complexité de calcul et minimiser le facteur temps de décision. Dans ce cas, trois couches sont fixées : La couche d'entrée, la couche cachée et la couche de sortie.


La couche d'entrée a une seule entrée pour les valeurs réelles et imaginaires (traitement sériel). La couche cachée contient seulement une couche de neurones (10 à 30 pour le MLP et 20 à 50 pour le RBF en fonction de M-QAM). La couche de sortie n'a qu'une seule sortie (figure IV.9).

Pour la fonction d'activation de la couche cachée, notre choix s'est porté sur la fonction non linéaire tangente hyperbolique, car la plupart du temps, *tanh* converge rapidement par rapport aux fonctions sigmoïdes et logistiques, et

effectue une meilleure précision [49]. Elle a de meilleures approximations en classification car sa sortie est centrée sur zéro (sa plage d'intervalle est [-1, 1]).



**Figure IV.8.** Classification de constellation 64 QAM (64 zones de décision) réduite à la classification de symboles complexes divisée (8 zones de décision).



**Figure IV.9.** Structure RBF simplifiée pour la décision des symboles avec une seule entrée, une seule sortie et une seule couche cachée avec le nombre adéquat de neurones.

Le tableau IV.3 nous donne un récapitulatif du design des architectures et tous les paramètres des égaliseurs MLP et RBF, et cela pour toutes les

modulations M-QAM utilisées et avec plusieurs niveaux de bruits sur le canal de transmission  $H$ . Les architectures ont été conçues pour être simples (nombre de couches et de neurones) afin de minimiser le temps et la complexité de calcul, ce qui nécessite les processus d'égalisation.

Parameters	MLP	RBF
Criterion Function	MSE	MSE
Hidden Layers	1	1
Hidden layer neurons	10~30	20~50
Input layer neurons	1	1
Output layer neurons	1	1
Parameters	Weights $w$	Centroids $C_i$
	Step $\mu$	Widths $\sigma_i$
	Iteration $n$	Weight $\lambda_i$
Algorithm	Back-propagation	Euclidian Norm
Activation function	Hyperbolic-tangent	Gaussian
Learning	Supervised	Supervised + unsupervised

*Tableau IV.3. Récapitulatif des paramètres des égaliseurs ANN.*

#### IV.4.2. Evaluation en termes de MSE

Toutes les modulations HOM et leurs valeurs MSE sont représentées sur les figures IV.10 et IV.11, où les valeurs MSE sont exprimées en termes de multiple SNR. Le LMS et le RLS ont des valeurs MSE excessives de l'ordre de  $10^2$  à  $10^4$ . Cela montre que les égaliseurs linéaires ont des performances médiocres, en particulier sur les valeurs faibles de SNR.

MLP et RBF montrent une grande résistance aux effets de canal où le MSE est de l'ordre de  $10^{-4}$  à 5 avec 16, 64 et 128 QAM, et de l'ordre de 5 à  $10^2$  pour 256, 512 et 1024 QAM.

En QAM 16 et 512, le MSE de MLP et RBF sont presque les mêmes. En QAM 64 et 128, le MSE du RBF est meilleur ; et en 256 et 1024 QAM, le MSE du MLP est meilleur.

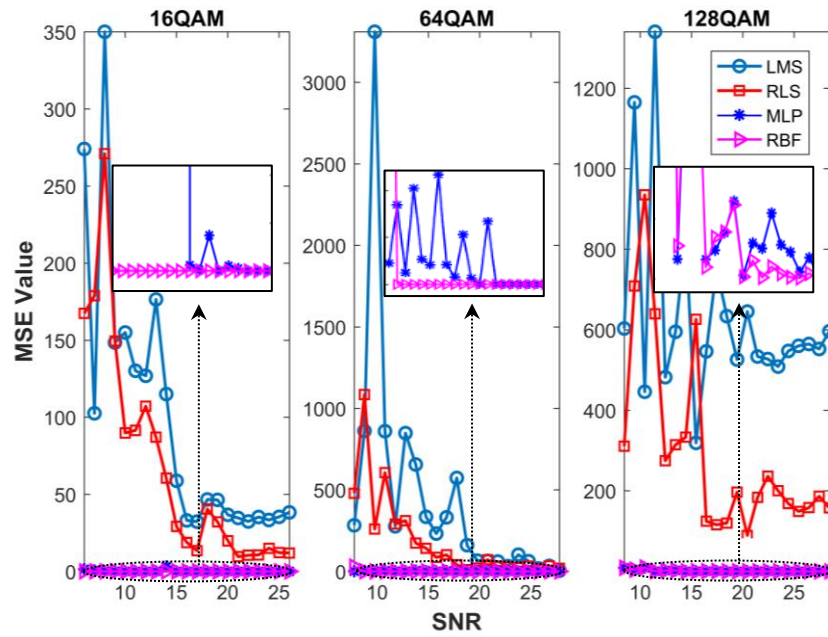


Figure IV.10. Effet du SNR sur le MSE des égaliseurs sur 16, 64, et 128 QAM.

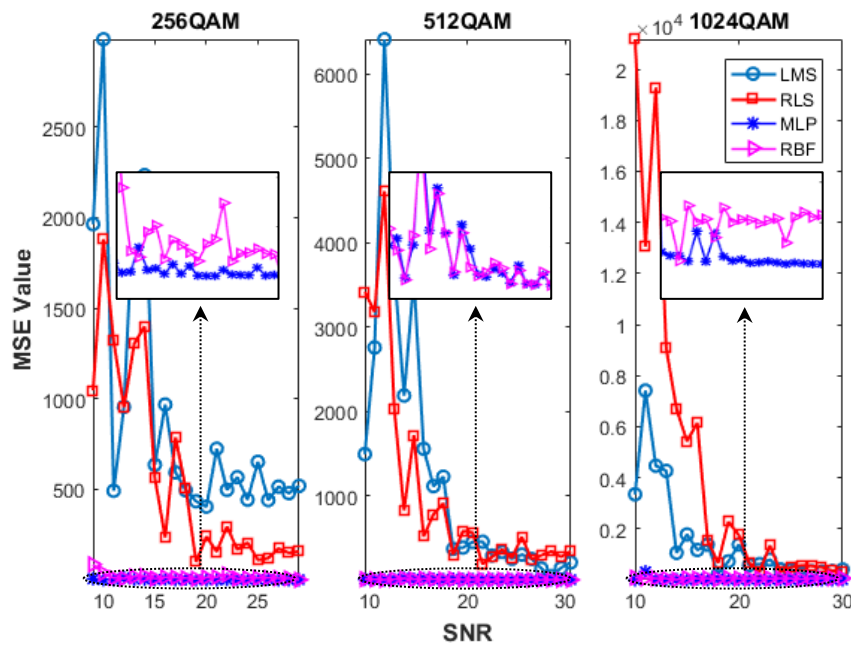



Figure IV.11. Effet du SNR sur le MSE des égaliseurs sur 256, 512, et 1024 QAM.

A partir des courbes de la figure IV.12 qui représentent une comparaison de MSE du MLP et RBF sur 256 QAM avec une architecture de neurone

différente (meilleure configuration sur 256 QAM), une légère amélioration au niveau des faibles SNR (canaux bruités) est observée dans l'égaliseur MLP avec 20 neurones. Sur le reste, ils ont presque le même aspect. RBF a une performance modérée, en particulier sur les faibles valeurs de SNR.



*Figure IV.12. MSE d'égaliseurs MLP et RBF sur 256 QAM avec le nombre optimal de neurones dans leurs couches cachées*

### IV.4.3. Tracking

Les figures IV.13 et IV.14 représentent un exemple de performance de tracking (suivi) de la partie réelle estimée des symboles complexes par les égaliseurs avec 64 QAM et 128 QAM sous 28 dB de SNR. Le MLP et le RBF montrent d'excellentes performances et disposent d'un bon suivi des données avec une erreur minimale.






Figure IV.13. Performances de tracking (suivi) des symboles 64 QAM à SNR = 28 dB.


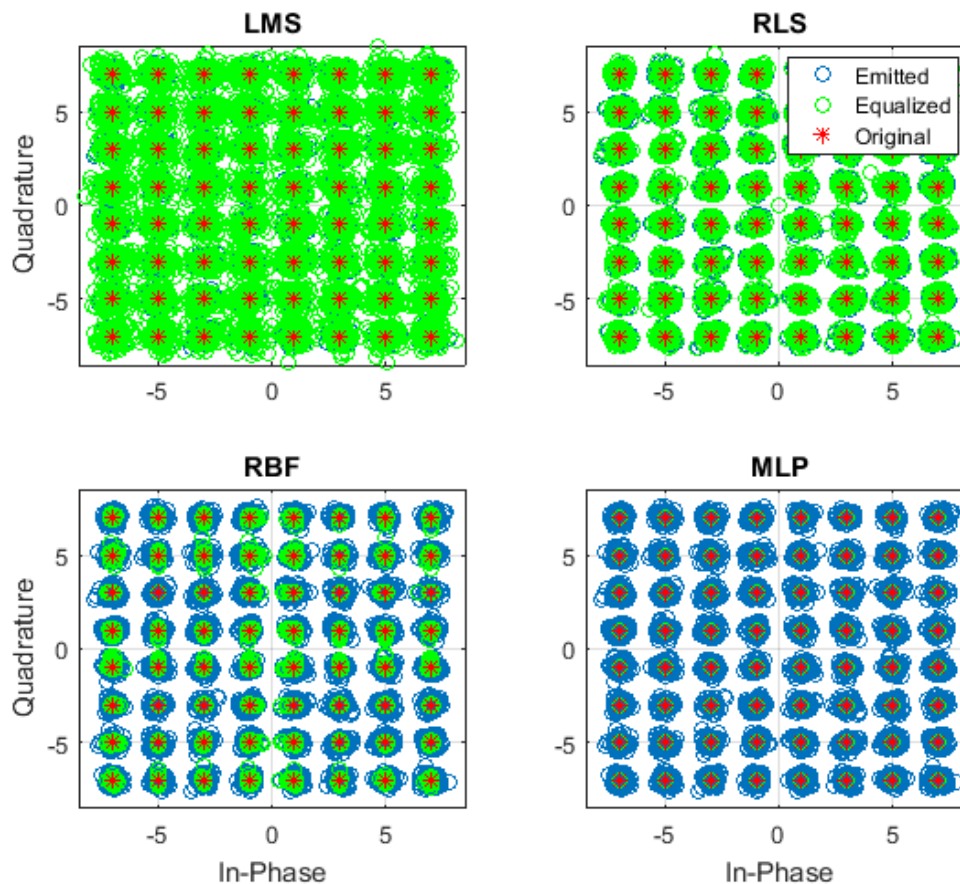


Figure IV.14. Performances de tracking (suivi) des symboles 128 QAM à SNR = 28 dB.

Dans le cas de 64 QAM (figure IV.13), MLP est meilleur que les autres égaliseurs ; RBF a de bonnes performances ; RLS est modéré. Le LMS a les performances les plus faibles en termes de robustesse face aux canaux bruités.

Dans le cas de 128 QAM (figure IV.14), le RBF est efficace avec un minimum d'erreurs par rapport aux autres ; le MLP pose des problèmes de décision autour de certaines constellations (-9, 1, 9). RLS et LMS ont les mêmes performances modérées ; le LMS a des problèmes d'initialisation qui le rendent difficile à stabiliser avant un certain temps (100 itérations pour stabiliser les coefficients  $w_n$ ). Les égaliseurs MLP et RBF ont un très bon suivi avec une très petite erreur par rapport au LMS et au RLS ; ils sont stables et rapides.

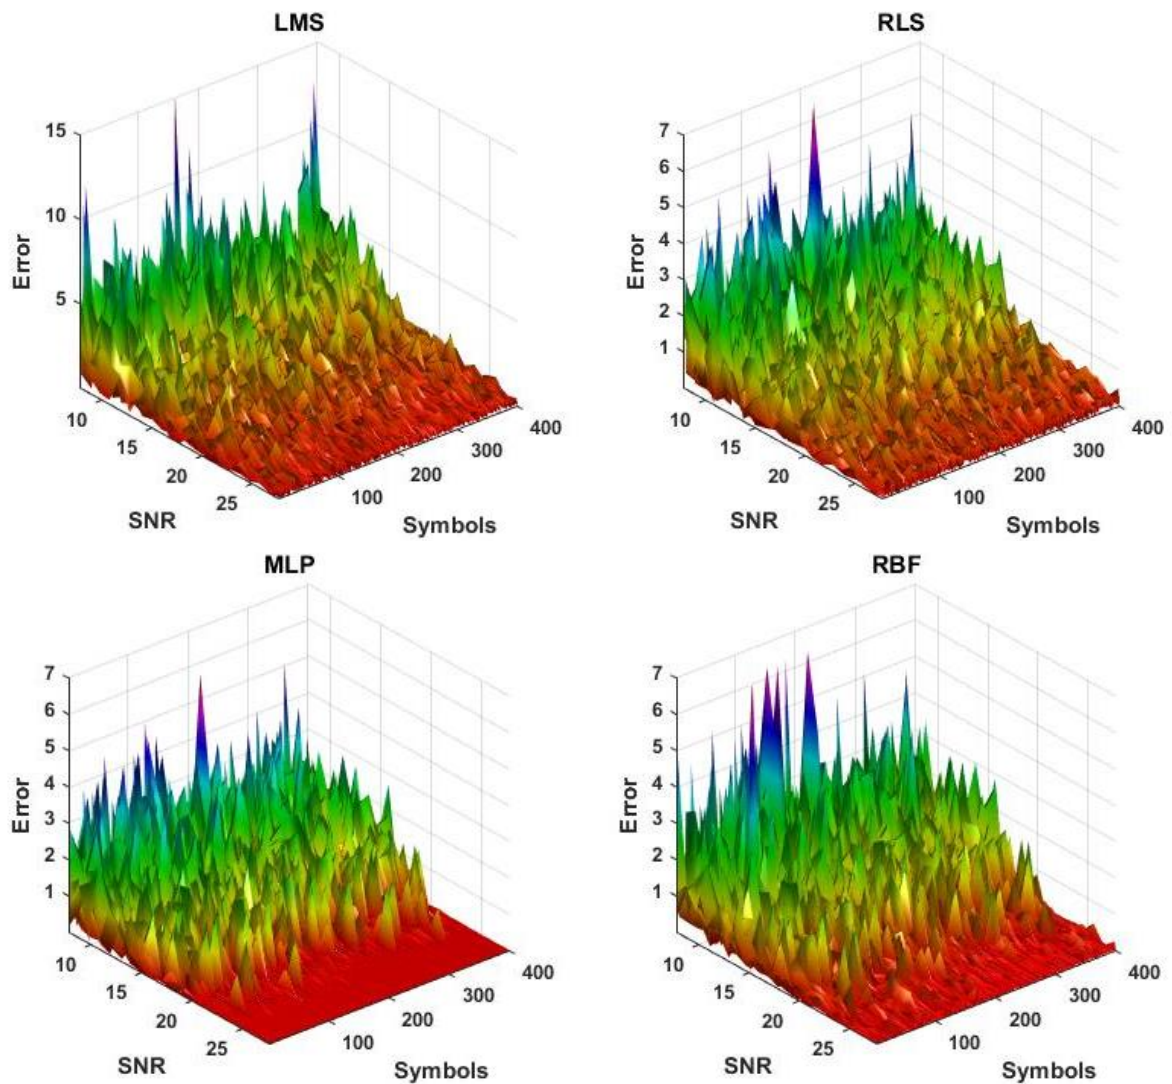
La figure IV.15 illustre la bonne adaptation de l'erreur du MLP et RBF et la bonne convergence des séquences émises pour 64 QAM. Toutes les séquences sont égalisées correctement dès le début pour atteindre les valeurs optimales sans initialisation ou besoin de temps pour s'adapter ; le contraire se produit pour LMS et RLS.



**Figure IV.15.** Constellations 64 QAM montrant le processus d'égalisation pour LMS, RLS, RBF et MLP avec SNR = 28 dB.

Un tracé de surface 3D sur la figure IV.16 représente une visualisation des performances des quatre égaliseurs considérés avec 64 QAM. MLP est plus approprié et effectue une égalisation avec moins d'erreurs sur la partie réelle des symboles complexes.

Lorsque le canal est vraiment dispersif et bruité, l'égaliseur MLP présente une grande résistance au bruit additif. Il convient le mieux à ce type de canal. En ce qui concerne l'égaliseur RBF, il est proche du MLP mais plus complexe, et met plus de temps en traitement. Les égaliseurs RLS et LMS offrent d'excellentes performances pour les canaux bruités modérément avec 64 QAM.



**Figure IV.16.** Performances et robustesse du MLP, RBF, LMS et RLS avec 64 QAM en fonction de l'erreur de parties réelles des symboles sur un ensemble fini.

#### IV.4.4. Evaluation en termes de BER

Nous exposons d'abord le BER théorique de chaque M-QAM. Ici, le BER théorique est considéré comme une référence pour mesurer l'efficacité des égaliseurs couplés à des facteurs dégradant le signal tels que le SNR, le type de canal et la sensibilité de la modulation utilisée. Le BER théorique est calculé via l'équation [50] :

$$P_b = \frac{2}{\sqrt{M} \log_2 \sqrt{M}} \sum_{k=1}^{\log_2 \sqrt{M}} \sum_{i=0}^{(1-2^{-k})\sqrt{M}-1} \left\{ (-1)^{\lfloor \frac{i2^{k-1}}{\sqrt{M}} \rfloor} \left( 2^{k-1} - \left\lfloor \frac{i2^{k-1}}{\sqrt{M}} + \frac{1}{2} \right\rfloor \right) Q(\varphi) \right\} \quad (\text{IV.2})$$

$$\varphi = \left( (2i+1) \sqrt{\frac{6 \log_2 M E_b}{2(M-1) N_0}} \right) \quad (\text{IV.3})$$

où  $P_b$  est le BER, et  $Q(x)$  est la fonction mathématique  $Q$  donnée par :

$$Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^{\infty} \exp(-t^2/2) dt = \frac{1}{\sqrt{\pi}} \int_x^{\infty} \exp(-z^2) dz = \frac{\text{erfc}(x)}{2} \quad (\text{IV.4})$$

où  $\text{erfc}(x)$  est la fonction d'erreur complémentaire, accessible dans le logiciel Matlab.

##### IV.4.4.1. 16 QAM


Avec 16 QAM (figure IV.17), les égaliseurs RLS et LMS commencent à diverger de la courbe théorique à 11 dB, à la même valeur  $E_b/N_0$  une légère amélioration est remarquée dans le cas de MLP et RBF.

A  $E_b/N_0 = 12$  dB, une amélioration de 1 dB est observée pour les deux. Les deux ont des performances identiques dans ce schéma de modulation.

##### IV.4.4.2. 64 QAM

Avec 64 QAM (figure IV.17), les performances LMS ne sont pas assez bonnes pour la courbe théorique, RLS et RBF sont meilleurs mais commencent à

diverger à 15 dB. MLP fonctionne comme la courbe théorique, il est le plus adapté pour le 64 QAM.



**Figure IV.17.** Courbes de performance BER des égaliseurs avec 16 et 64 QAM.

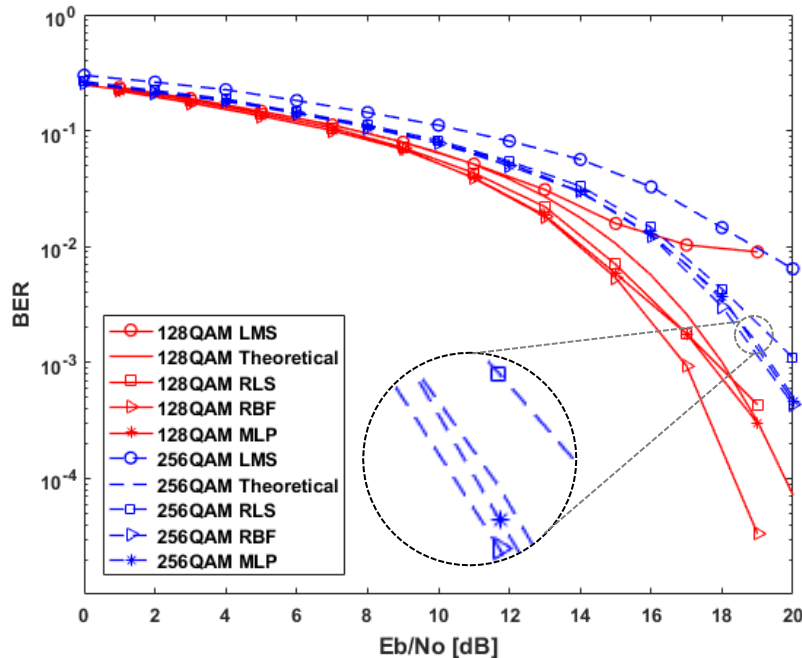
#### IV.4.4.3. 128 QAM

Avec 128 QAM (figure IV.18), LMS et RLS commencent à diverger à 13 dB et à 18 dB, respectivement. MLP fonctionne mieux que les égaliseurs linéaires, il a pu gagner presque 1 dB, mais RBF est le plus adapté pour ce schéma de modulation en améliorant presque 2 dB par rapport à la courbe théorique.

#### IV.4.4.4. 256 QAM

Avec 256 QAM (figure IV.18), MLP et RBF sont très proches de la courbe théorique. Une légère amélioration est observée sur les performances RBF par rapport à MLP. RLS est meilleur que LMS mais commence à diverger à 18 dB. Cette performance est basée sur une configuration de 10 et 20 neurones pour le

MLP et RBF, respectivement. Cette similarité nous a poussé à reconfigurer les architectures des réseaux pour trouver la meilleure adaptation.



**Figure IV.18.** Courbes de performance BER des égaliseurs avec 128 et 256 QAM.

La figure IV.19 représente les courbes BER pour un nombre différent de neurones dans la couche cachée de l'égaliseur MLP. Les courbes de MLP sont identiques à la courbe théorique où on observe une légère amélioration à partir de 16 dB. A 20 dB, les courbes à 20 et 30 neurones ont un BER amélioré, spécialement avec 20 neurones, qui réalise la meilleure configuration en architecture MLP ; avec 10 neurones la courbe diverge à 19 dB.

La figure IV.20 décrit les courbes BER pour un nombre différent de neurones dans la couche cachée de l'égaliseur RBF. Les courbes de RBF sont différentes de la courbe théorique. Les architectures avec la configuration 10 et 30 neurones divergent respectivement à 10 et 16 dB, ce qui montre une performance médiocre. En même temps, à 16 dB, une légère amélioration est observée avec les courbes à 40 et 50 neurones par rapport à la courbe théorique

de 256 QAM. Elles ont un BER amélioré, en particulier avec 40 neurones, qui est la meilleure configuration de l'architecture RBF.




Figure IV.19. Courbes BER de l'égaliseur MLP avec de différents nombres de neurones dans la couche cachée pour 256 QAM.





Figure IV.20. Courbes BER de l'égaliseur RBF avec de différents nombres de neurones dans la couche cachée pour 256 QAM.

Une comparaison du BER entre les architectures les plus efficaces dans MLP et RBF est présentée dans la figure IV.21 : RBF avec 40 neurones et MLP avec 20 neurones. De manière surprenante, ils sont presque identiques à la courbe théorique et présentent une légère amélioration à partir de 16 dB.



**Figure IV.21.** Courbes de performance BER d'égaliseurs MLP et RBF sur 256 QAM avec le nombre optimal de neurones dans leurs couches cachées

#### IV.4.4.5. 512 QAM

Avec 512 QAM, l'efficacité spectrale est vraiment élevée (9 bits par symbole). Comme mentionné précédemment, cette modulation est sensible à un bruit excessif et a besoin de plus de SNR pour être investiguée par rapport aux modulations basses.


La figure IV.22 montre les performances de cette modulation. A 512 QAM, les deux égaliseurs linéaires divergent, RBF suit la courbe théorique mais diverge à 23 dB. MLP fonctionne nettement bien pour gagner 1,5 dB ; il est mieux adapté à la modulation 512 QAM que d'autres égaliseurs.



#### IV.4.4.6. 1024 QAM

Dans ce cas, l'efficacité spectrale est la plus élevée (10 bits par symbole). Cette modulation est sensible à un bruit excessif et nécessite plus de SNR pour être investiguée.

Avec 1024 QAM, le MLP est plus efficace que RLS, LMS et RBF (figure IV.22) qui ne suivent pas la courbe théorique. RBF a des performances médiocres comparé aux LMS et RLS. Nous avons essayé de l'entraîner différemment et d'étendre l'architecture de RBF avec plus de neurones (jusqu'à 40 neurones), malheureusement, il n'y avait pas d'amélioration. MLP est le plus approprié pour cette haute efficacité spectrale.



**Figure IV.22.** Courbes de performance BER des égaliseurs avec 512 et 1024 QAM.

Les égaliseurs neuraux développés montrent une grande résistance et une excellente robustesse en termes d'adaptation. Les symboles sont correctement égalisés à partir du point de départ avec un meilleur BER dans la plupart des cas que la simulation théorique. Lorsque le canal est dans un état SNR diminutif, les égaliseurs MLP et RBF ne souffrent d'aucune dégradation des performances, et

ils sont plus appropriés pour ce type de canal couplé avec HOM. Cependant, les égaliseurs RLS et LMS ont de meilleures performances pour des niveaux de bruit faibles et modérés avec HOM.

#### IV.4.5. Profilage des égaliseurs

Le tableau IV.4 représente le profilage des algorithmes d'égalisation lors du traitement des données (toutes les séquences et toutes les étapes de l'apprentissage sont tenues en compte). Les calculs d'initialisation et de MSE ne sont pas pris en compte. La moyenne des mesures (mesure de temps refaite 10 fois) est indiquée dans le tableau pour chaque algorithme. 256 QAM est choisi parce que, en termes de BER, les égaliseurs fonctionnent presque de la même manière et ont des performances avoisinantes. LMS a la durée la plus courte en raison de sa simplicité. RLS est plus complexe et prend plus de temps et fonctionne de manière similaire à MLP (10 neurones). Ce dernier, à une bien meilleure vitesse, nous donne un bon résultat en termes de MSE et de BER. RBF prend beaucoup de temps depuis que son architecture a été étendue (plus de neurones) pour atteindre de meilleurs résultats en termes de BER.

Egaliseur	LMS	RLS	MLP		RBF	
Nombre de $w_n$ /neurones	10	10	10	20	20	40
Temps (s)	0.239644	0.451853	0.542335	1.6685072	0.972604	2.2189923

*Tableau IV.4. Profilage de la performance vitesse des égaliseurs avec 256 QAM à  $E_b/N_o = 20$  dB.*

## IV.5. Conclusion

Dans ce chapitre, les égaliseurs MLP et RBF ont été développés sous une forme simple afin d'égaliser HOM en tant que clé et d'assurer plus d'efficacité spectrale. Les résultats de la simulation montrent que les valeurs MSE des deux égaliseurs ANN sont négligeables par rapport à LMS et RLS. En outre, le BER

est amélioré dans la plupart des cas de M-QAM et donne d'excellentes performances dans le traitement HOM malgré la complexité (par rapport aux égaliseurs linéaires). Ces modèles sont plus fiables et efficaces en termes d'annulation de bruit (critère MSE) et de performances de réduction du taux d'erreur (critère BER).

# Conclusion générale

Lors d'une transmission de données entre l'émetteur et le récepteur, le canal de transmission peut avoir plusieurs effets sur le signal transmis. Le canal est souvent symbolisé comme une source de bruit additif mais il peut aussi atténuer fortement certaines fréquences porteuses, on parle alors de fading sélectif. Le canal peut aussi avoir pour effet de "mélanger" les symboles transmis ; on parle alors d'interférences entre symboles.

L'égalisation adaptative consiste à pallier le mieux possible les déformations apportées par le canal de transmission au signal utile grâce à des filtres qui changent de coefficients en temps réel.

Dans cette thèse, nous avons traité deux techniques d'égalisation ; égalisation linéaire et non linéaire. Les propriétés et la convergence des filtres adaptatifs linéaires et non linéaires complexes ont été étudiés.

Les algorithmes les plus utilisés dans l'égalisation adaptative linéaire sont LMS et RLS. Le LMS montre relativement une bonne convergence, mais il est moins rapide par rapport à l'algorithme RLS en ce qui concerne l'égalisation adaptative avec apprentissage.

La modulation à ordre supérieur (HOM) est un choix très attrayant pour augmenter l'efficacité du spectre en envoyant plus de données dans la même bande passante, ce qui nous permet d'avoir un pic de débit bien plus important. Par contre HOM est influencée par la sensibilité au bruit, les distorsions du canal, et même les interférences de cellules adjacentes.

Nous nous sommes proposés de concevoir deux égaliseurs non linéaires basés sur deux modèles de réseaux de neurones MLP et RBF dans le but d'optimiser les performances du traitement de l'HOM, son tracking, et de

minimiser l'erreur vis-à-vis des effets du canal et du bruit. Les deux égaliseurs neuronaux non linéaires MLP et RBF que nous avons développés ont donné des performances notables par rapport aux égaliseurs classiques, en ce qui concerne la robustesse vis-à-vis du bruit, l'erreur du modèle, ou la reconstitution des séquences originelles (élimination des facteurs ISI et MAI).

Par souci de simplicité d'une part et de réalisation meilleures performances d'autre part, nous avons proposé de diviser les symboles complexes modulés en parties réelles et imaginaires en vue d'un traitement série et séparé. Cette pratique nous a conduit à trouver des égaliseurs simples et ayant un profilage performant.

L'égaliseur MLP est bien adapté par rapport à l'égaliseur RBF avec 64, 512 et 1024 QAM, et presque à l'identique avec le RBF avec 16 et 256 QAM. Le RBF est performant seulement avec 128 QAM.

Grâce à la planification de petites cellules (annulation d'ICI), les HOM associées à l'égaliseur MLP constituent une option afin d'améliorer l'efficacité du spectre et augmenter les pics de débit des données.

Comme continuité de ce travail, il serait intéressant d'améliorer et de développer d'autres nouvelles stratégies (utilisation d'algorithmes méta-heuristiques tels que les algorithmes génétiques et PSO (Particle Swarm Optimization)) pour accélérer la convergence et aussi pour avoir une régulation de la fonction de coût ; ce qui doit réduire la complexité de calcul due au nombre de neurones.

L'application de ces égaliseurs avec les techniques des antennes multiples (MIMO) est une autre perspective en vue d'améliorer la sélection des antennes ou la gestion des pilotes pour avoir l'état d'un canal dynamique en temps réel.

# Références

- [1] Y. Tao, L. Liu, S. Liu and Z. Zhang, "A survey: Several technologies of non-orthogonal transmission for 5G," in *China Communications*, vol. 12, no. 10, pp. 1-15, Oct. 2015.
- [2] A. Gupta and R. K. Jha, "A Survey of 5G Network: Architecture and Emerging Technologies," in *IEEE Access*, vol. 3, pp. 1206-1232, 2015.
- [3] Y. Liu, Z. Lin and Z. Zhongpei, "High order QAM signals recognition based on layered modulation," 2009 International Conference on Communications, Circuits and Systems, Milpitas, CA, 2009, pp. 73-76.
- [4] X. Zhao, L. Zhu, Y. Guo and X. Gou, "Simulations of Low-Density Parity-Check Codes under high-order modulation," *Proceedings of 2012 5th Global Symposium on Millimeter-Waves*, Harbin, 2012, pp. 482-485.
- [5] H. ShahMohammadian and A. Aharony, "Accurate BCJR-based synchronization algorithm for single carrier channels with extremely high order modulations," 2016 10th International Conference on Signal Processing and Communication Systems (ICSPCS), Gold Coast, QLD, 2016, pp. 1-6.
- [6] M. Jordão, R. Correia and N. B. Carvalho, "High order modulation backscatter systems characterization," 2018 IEEE Topical Conference on Wireless Sensors and Sensor Networks (WiSNet), Anaheim, CA, 2018, pp. 44-46.
- [7] K. Burse, R. N. Yadav and S. C. Shrivastava, "Channel Equalization Using Neural Networks: A Review," in *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 40, no. 3, pp. 352-357, May 2010.

- 
- [8] [www.3gpp.org](http://www.3gpp.org)
- [9] G. De la Roche, A. Alayón-Glazunov, and B. Allen, “LTE-advanced and next generation wireless networks: channel modelling and propagation”, John Wiley & Sons, 2012.
- [10] L. Deneire, “Réseaux locaux et personnels sans fil“, GTR-Sophia-Antipolis, Avril 2003.
- [11] A. Sassan, “*LTE-advanced: A practical systems approach to understanding 3GPP LTE releases 10 and 11 radio access technologies*”, Academic Press, 2013.
- [12] Overview of 3GPP Release 8 V0.3.3 (2014-09) available at [http://www.3gpp.org/ftp/Information/WORK\\_PLAN/Description\\_Releases/Rel-08\\_description\\_20140924.zip](http://www.3gpp.org/ftp/Information/WORK_PLAN/Description_Releases/Rel-08_description_20140924.zip).
- [13] Overview of 3GPP Release 10 V0.2.1 (2014-06) available at [http://www.3gpp.org/ftp/Information/WORK\\_PLAN/Description\\_Releases/Rel-08\\_description\\_20140924.zip](http://www.3gpp.org/ftp/Information/WORK_PLAN/Description_Releases/Rel-08_description_20140924.zip).
- [14] A. R. Mishra, “Fundamentals of Cellular Network Planning and Optimisation 2G/2.5G/3G... Evolution to 4G “, Edition John Wiley & Sons, 2004.
- [15] A. Goldsmith, “Wireless Communications”, Cambridge University Press, 2005.
- [16] R. L. Howald, “QAM bulks up once again: Modulation to the power of ten,” in Proc. of SCTE Cable-tec EXPO, 2002.
- [17] A. Darwish and A. S. Ibrahim, "Capacity improvement via indoor small cells," *2014 International Wireless Communications and Mobile Computing Conference (IWCMC)*, Nicosia, 2014, pp. 69-73.
- [18] M. Iwamoto, S. Matsuoka, H. Iwasaki and H. Otsuka, "Transmission performance of OFDM with 1024-QAM in the presence of EVM degradation," *Wireless and Mobile, 2014 IEEE Asia Pacific Conference on*, Bali, 2014, pp. 12-16.

- 
- [19] S. Ma and Y. Chen, "FPGA Implementation of High-Throughput Complex Adaptive Equalizer for QAM Receiver," *Wireless Communications, Networking and Mobile Computing (WiCOM), 2012 8th International Conference on*, Shanghai, 2012, pp. 1-4.
- [20] F. Bouguerra, "Contribution à l'optimisation des télécommunications dans les réseaux mobiles", thèse de Magister, Université of Batna, 2011.
- [21] [www.mathworks.com](http://www.mathworks.com).
- [22] S. Paulo, R. Diniz, "Adaptive Filtering: Algorithms and Practical Implementation," 4th Edition, Springer Science, 2013.
- [23] E. S. Gopi, "Multi-Disciplinary Digital Signal Processing", Springer Science, 2018.
- [24] R. K. Deerga, and M. N. S. Swamy. Adaptive Digital Filters. In: R. K. Deerga, and M. N. S. Swamy. Digital Signal Processing, Singapore: Springer; 2018, pp. 693-719.
- [25] S. C. Douglas, R. Losada, "Adaptive filters in Matlab : from novice to expert", Digital Signal Processing Workshop and the 2nd Signal Processing Education Workshop, IEEE Papers, 2002.
- [26] S. Haykin, "Adaptive filter theory ", 5<sup>th</sup> Edition, Pearson Edition, 2014.
- [27] S. Haykin, and B. Widrow, "Least-mean-square adaptive filters", Vol. 31. John Wiley & Sons, 2003.
- [28] F. S. Cattivelli, G. L. Cassio, and A. H. Sayed. "Diffusion recursive least-squares for distributed estimation over adaptive networks." *IEEE Transactions on Signal Processing* 56.5 (2008): 1865-1877.
- [29] K. Skretting and E. Kjersti. "Recursive least squares dictionary learning algorithm." *IEEE Transactions on Signal Processing* 58.4 (2010): 2121-2130.



- 
- [30] F. P. FontÅæn and M. E. Perfecto “Modelling the wireless propagation channel: a simulation approach with Matlab”. Vol. 5. John Wiley & Sons, 2008.
- [31] J. G. Proakis, M. Salehi “Digital Communications”, 5<sup>th</sup> Edition, McGraw-Hill edition, 2008.
- [32] M. Parizeau, “Réseaux de Neurones GIF-21140 et GIF-64326“, Université de Laval, 2006.
- [33] F. Toshio and S. Takanori, “Theory and applications of neural networks for industrial control systems”, IEEE Transactions on industrial electronics, Vol. 39, No. 6, December 1992.
- [34] S. M. Shamsuddin, M. N. Sulaiman, and M. Darus. "An improved error signal for the backpropagation model for classification problems." International Journal of Computer Mathematics 76, no. 3,2001, pp. 297-305.
- [35] S. Haykin, “Neural networks and learning machines”, 3rd edition, New Jersey, USA: Pearson Education, Inc., Upper Saddle River, 2009.
- [36] F. Bouguerra, I. Benacer, L. Saidi, “MLP and RBF symbol tracking with 16 QAM modulation over multipath distorted channel”, 2017 International Conference on Advanced Systems and Electric Technologies, (IC\_ASET), Hammamet, Tunisia, 2017, pp. 182-187.
- [37] S. Siu, G. J. Gibson and C. F. N. Cowan, "Decision feedback equalization using neural network structures," 1989 First IEE International Conference on Artificial Neural Networks, (Conf. Publ. No. 313), London, 1989, pp. 125-128.
- [38] T. Fechner, "Nonlinear noise filtering with neural networks: comparison with Weiner optimal filtering," 1993 Third International Conference on Artificial Neural Networks, Brighton, 1993, pp. 143-147.

- 
- [39] S. K. Nair. and J. Moon, "Data storage channel equalization using neural networks", *IEEE Transactions on Neural Networks*, 1997, 8(5): 1037-1048. DOI: 10.1109/72.623206
- [40] P. Chandra Kumar, P. Saratchandran and N. Sundararajan, "Minimal radial basis function neural networks for nonlinear channel equalisation," in *IEE Proceedings - Vision, Image and Signal Processing*, vol. 147, no. 5, pp. 428-435, Oct 2000.
- [41] C. Botoca and B. Georgeta, "Symbol decision equalizer using a radial basis functions neural network." In *Proc. 7th WSEAS Int. Conf. Neural Networks (Cavta, Croatia)*. 2006, pp. 79-84.
- [42] J. C. Patra, Wei Beng Poh, N. S. Chaudhari and A. Das, "Nonlinear channel equalization with QAM signal using Chebyshev artificial neural network," *Proceedings. 2005 IEEE International Joint Conference on Neural Networks*, vol. 5, 2005, pp. 3214-3219.
- [43] J. C. Patra, W. C. Chin, P. K. Meher and G. Chakraborty, "Legendre-FLANN-based nonlinear channel equalization in wireless communication system," *2008 IEEE International Conference on Systems, Man and Cybernetics, Singapore*, 2008, pp. 1826-1831.
- [44] S. Panda, A. Sarangi, S. P. Panigrahi, "A new training strategy for neural network using shuffled frog-leaping algorithm and application to channel equalization". *AEU-International Journal of Electronics and Communications*, 2014, 68 (11): 1031-1036.
- [45] H. Cai, Q. Zhang, Q. Li and J. Qin, "Proactive Monitoring Via Jamming for Rate Maximization Over MIMO Rayleigh Fading Channels," in *IEEE Communications Letters*, vol. 21, no. 9, pp. 2021-2024, Sept. 2017.
- [46] Y. A. LeCun, et al., "Efficient backprop." *Neural networks: Tricks of the trade*. Springer, Berlin, Heidelberg, 2012. pp. 9-48.

- [47] S. Ioffe, C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift", arXiv preprint arXiv:1502.03167, Feb 11, 2015.
- [48] P. M. Danilo, V. S. L. Goh, "Complex Valued Nonlinear Adaptive Filters: Noncircularity, Widely Linear and Neural Models," Edition John Wiley & Sons, 2009.
- [49] B. Karlik, and A. V. Olgac, "Performance analysis of various activation functions in generalized MLP architectures of neural networks", International Journal of Artificial Intelligence and Expert Systems, vol 1, no 4, pp. 111-122, 2011.
- [50] C. Kyongkuk and Y. Dongweon, "On the general BER expression of one- and two-dimensional amplitude modulations," in IEEE Transactions on Communications, vol. 50, no. 7, pp. 1074-1080, Jul 2002.

# Travaux scientifiques réalisés

## 1. Publication Internationale

- F. Bouguerra and L. Saidi, “An Efficient ANN Interference Cancellation for High Order Modulation over Rayleigh Fading Channel”, *Journal of Telecommunications and Information Technology (JTIT)*, Vol 2018, No 04, December 2018.

## 2. Conférences Internationales

- F. Bouguerra, L. Saidi, “High Order Modulation BP-ANN Symbol Decision Making Over OFDM AWGN Channel”, *3<sup>rd</sup> International Conference on Embedded Systems in Telecommunications and Instrumentation (ICESTI'16)*, Annaba - Algeria, October 24-26, 2016.
- F. Bouguerra, L. Saidi, “ANN Symbol Decision Making in Multipath Distorted Channel with QPSK Modulation”, *2<sup>nd</sup> International Conference on Pattern Analysis and Intelligent Systems (PAIS'16)*, Khenchela - Algeria, November 16-17, 2016.
- F. Bouguerra, I. Benacer, L. Saidi, “MLP and RBF Symbol Tracking with 16 QAM Modulation Over Multipath Distorted Channel”, *2017 International Conference on Advanced Systems and Electric Technologies (IC\_ASET)*, Hammamet - Tunisia, January 14-17, 2017, pp. 182-187 (IEEE Catalog Number CFP17J92-ART).
- F. Bouguerra, L. Saidi, “Simplified ANN for 256 QAM Symbol Equalization Over OFDM Rayleigh Channel”, *7<sup>th</sup> IEEE International Conference on Smart Communications in Network Technologies (SaCoNeT'18)*, El Oued - Algeria, October 27-31, 2018.

## 3. Conférences Nationales

- F. Bouguerra, L. Saidi, “RBF Applied on Interference Cancellation on Distorted Channel”, *1<sup>st</sup> National Seminar of mathematics (SNM'01)*, Constantine - Algeria, December 13, 2016.
- F. Bouguerra, L. Saidi, “Artificial Neural Network Applied on Channel Equalization”, *1<sup>st</sup> National Seminar on Numeric Simulation in Applied Sciences (SNSA I-2016)*, Guelma - Algeria, December 15, 2016.