

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8 Mai 1945 Guelma



Faculté : Sciences et technologies
Département : Electronique et télécommunications

MÉMOIRE

EN VUE DE L'OBTENTION DU DIPLOME DE
MASTER

Filière : Systèmes de télécommunications

Intitulée

**Estimation du canal par apprentissage profond dans un système
OFDM**

Présentée par :

**ABDAOUI Ahmed Ramzi
SEDDIKI Ishaq**

Sous la direction de :

Dr. GHADJATI Mohamed

Année Universitaire : 2020/2021

Remerciements

Nos remerciements vont tout premièrement au bon Dieu, le tout puissant, qui nous a éclaircie le chemin du savoir et pour la volonté, la santé et la patience, qu'il nous a donnée durant toutes ces longues années.

Nous voudrions, avant toute chose, exprimer ma plus grande reconnaissance à mon encadreur Monsieur Ghadjati Mohammed, Docteur à l'Université de Guelma, qui a su diriger ce travail avec diplomatie, efficacité et rigueur. Je lui en témoigne ici toute ma gratitude.

Nous exprimons mes remerciements aux membres de jury, d'avoir bien voulu consacrer du temps et de l'attention à mon travail, et qui ont accepté d'être examinateurs.

Nous tenons à exprimer également ma gratitude à tous nos enseignants du Département d'électronique et de télécommunications.

Pour finir, nous ne saurons exprimer à quel point je remercie nos famille pour son soutien et ses encouragements depuis toujours. Ce sont mes parents qui m'ont appris à donner le meilleur et c'est cette exigence de soi qui m'a aidée tout au long de mes études ; à mes parents je dédie ce travail. Mes amis sont également à remercier, pour leur soutien inconditionnel, ainsi que l'ensemble des personnes qui, de près ou de loin, ont contribué à la réalisation de ce travail.

Dédicace

Nous dédions ce travail à nos chères familles, à nos précieuses mamans qui nous a inspirés chaque instant, à non tendre papas qui ont toujours illuminé nos vies, à nos amis, nos alliés, à nos chers collègues et le cadre de l'université qui m'nous a accompagné tout au long de ces cinq années, nous avons appris, grandit et mûrit ensemble.

Que ce travail soit à la hauteur de toute bonne attente.

Résumé

L'OFDM (orthogonal frequency-division multiplexing) est un procédé de codage de signaux numériques par répartition en fréquences orthogonales sous forme de multiples sous-porteuses. Cette technique permet de lutter contre les canaux sélectifs en fréquence en permettant une égalisation de faible complexité. Chaque sous-porteuse est modulée indépendamment en utilisant des modulations numériques tel que : BPSK, QPSK, QAM-16, QAM-64. etc.

L'estimation de canal a un rôle très important dans les performances et l'efficacité des systèmes de communications sans fil. On présente deux méthodes permettant d'approcher l'estimateur de canal, appelé LMMSE (Linear Minimum Mean Square Error) et LS (least-squares).

Dans ce mémoire on va se focaliser sur l'estimation du canal par apprentissage profond car il est estimé plus applicable et performant que les méthodes classiques, les techniques de l'apprentissage profond ont permis des progrès importants et rapides et trouvent une place dans le domaine de communication et notamment avec la technique OFDM.

Une analyse des résultats obtenus de l'estimation du canal dans un système OFDM a l'aide de méthodes d'estimation classiques LS et MMSE et les techniques DL qui se base sur les techniques d'apprentissage profond est effectuée.

Sommaire

Remerciement	i
Dédicace	ii
Résumé	iii
Sommaire	iv
Liste Des Symboles et abréviations	viii
Liste des Figures	x
Introduction générale	xii
1. Chapitre 1 : Les éléments nécessaires pour la description d'un système de communication OFDM.	1
1.1 Introduction	1
1.2 Historique	2
1.3 Techniques de modulation OFDM	3
1.4 Les différents types de techniques OFDM	3
1.4.1 C-OFDM (coded-OFDM)	3
1.4.2 V-OFDM (Vector-OFDM)	3
1.4.3 W-OFDM (Wideband OFDM)	3
1.4.4 Flash OFDM	3
1.5 Notion d'orthogonalité	4
1.6 Principe de modulation OFDM	4
1.7 Les modulations numériques	6
1.7.1 La Modulation mPSK	8
1.7.2 La Modulation FSK	9
1.7.3 La Modulation PSK	10
1.7.4 La Modulation QAM	11
1.7.5 La Modulation multi-porteuses	12
1.8. Concept de CP	13
1.9. Principe de démodulation	15

1.10.	Démodulation cohérente et non-cohérente	15
1.10.1.	Démodulateur cohérent	15
1.10.2.	Démodulateur non-cohérent	16
1.11.	Canal de transmission	17
1.12.	Modèles de canaux de transmission	17
1.12.1.	Canal a bruit additif gaussien	18
1.12.2.	Canal de Rayleigh	19
1.13.	Les phénomènes perturbateurs dans les systèmes de communications	20
1.13.1.	Le bruit	20
1.13.2.	Propagation multi-trajet	20
1.14.	Avantages et inconvénients de l'OFDM	21
1.14.1.	Résistance aux interférences	21
1.14.2.	L'efficacité du spectre	21
1.14.3.	Résistant à L'ISI	21
1.14.4.	L'égalisation du canal plus simple	22
1.15.	Conclusion	22
2.	Chapitre 2 : Estimation classique du canal	23
2.1	Introduction	23
2.2	Techniques d'estimation	24
2.3.	Les Pilotes	24
2.3.1.	Structure des pilotes	25
2.3.1.1.	Configuration en Block	25
2.3.1.2.	Configuration en peigne	26
2.3.1.3.	Configuration en treillis	27
2.4.	L'erreur quadratique moyenne (MSE)	28
2.4.1.	Définition	28
2.5.	Bruit et interférences	29
2.5.1.	Signal-To-Noise Ratio, SNR	29
2.5.2.	Bit Error Rate (BER) ou Le taux d'erreur Binaire	29
2.6.	Estimation de canal basé sur les symboles d'apprentissage	30
2.7.	Méthodes classiques pour l'estimation de canal	31

2.7.1.	Méthodes d'estimation LS (Least Squares)	31
2.7.2.	Méthodes d'estimation LMMSE (Linear Minimum Mean Square Error)	32
2.8.	Techniques d'interpolation	35
2.8.1.	Interpolation nearest-neighbor ou plus proche voisin	35
2.8.2.	Interpolation linéaire	36
2.9.	Autres méthodes de l'estimation de canal	37
2.10.	Conclusion	37
3.	Chapitre 3 : L'intelligence artificielle et le Deep Learning	39
3.1.	Introduction	39
3.2.	Historique	40
3.3.	Définition de l'apprentissage profond	43
3.3.1.	Intérêt de l'apprentissage profond	43
3.3.2.	Domaines d'application de l'apprentissage profond	43
3.3.3.	Différentes structures de l'apprentissage profond	44
3.3.4.	Différents types d'apprentissage	44
3.3.4.1.	Apprentissage supervisé	44
3.3.4.2.	Apprentissage non-supervisé	45
3.3.4.3.	Apprentissage par renforcement	45
3.4.	Perceptron Multi couche (MLP, Multi-Layer Perceptron)	45
3.4.1.	Neurones d'entrée	46
3.4.2.	Neurones caché	46
3.4.3.	Neurones de sortie	46
3.4.4.	Fonction d'activation	46
3.5.	Algorithme de retro-propagation de l'erreur	47
3.5.1.	Formalisme mathématique de l'algorithme BP	48
3.6.	Réseaux de Neurone Profonds	50
3.6.1.	Avantages des réseaux profonds	51
3.6.2.	Inconvénient des réseaux profonds	51
3.7.	Langage de programmation Python Version 3.7.4	51
3.7.1.	Utilisation	52
3.7.2.	JetBrains Pycharm community Edition 2018.3.4	52
3.7.3.	Plateforme du deep learning Tensorflow	53

3.8. Conclusion	54
4. Chapitre 4 : Simulation et résultats	
4.1. Introduction	56
4.2. Architecture du système	56
4.3. Comparaison entre les performances du DNN et les autres estimateurs traditionnels	59
4.3.1. Résultats	60
4.3.2. Analyses et commentaires	
4.4. L'effet du nombre des pilotes sur les performances de DNN	61
4.4.1. Résultats	62
4.4.2. Analyses et commentaires	62
4.5. Conclusion	63
Conclusions générale	xv
Bibliographie	xvii

Liste des Symboles et abréviations

ASK	Amplitude Shift Keying
AWGN	Additive White Gaussian Noise
ANN	Artificial Neural Network
BPSK	Binary phase shift keying
BER	Bit Error Rate
CP	Cyclic Prefix
DL	Deep learning
DNN	Deep Neurone Network
FFT	Fast Fourier Transform
ICI	Inter Carrier Interference
ISI	Interférences inter symboles
IFFT	Inverse Fast Fourier Transform
IEC	Interférence Entre Canaux
IES	Interférence Entre Symboles
IA	Intelligence Artificielle
MSE	Mean square error (l'erreur quadratique moyenne)
MMSE	Minimum Mean Squared Error
MLP	Multi-Layered Perceptron
ML	Machine learning
OFDM	Orthogonal Frequency Division Multiplexing
PSK	Phase Shift Keying
P/S	parallel-to-serial conversion
QPSK	Quadrature Phase Shift Keying
QAM	Quadrature Amplitude Modulation
Q	en quadrature
RSB	Rapport Signal à Bruit
RNN	Recurrent Neural Network
RNA	Réseaux de Neurones Artificiels

RX	Receiver
SNR	Signal to Noise Ratio
S/P	Serial-To-Parallel Conversion
TEB	Taux d'Erreur Binaire
TX	Transmitter

Liste des figures

Chapitre 1

1.1.	Constituants de base d'une chaîne de communication numérique	2
1.2.	Représentation temporelle et fréquence du signal OFDM	4
1.3.	Chaîne de transmission OFDM	5
1.4.	Schéma de modulation OFDM	8
1.5.	Modulation d'amplitude ASK.	9
1.6.	Modulation de fréquence FSK	10
1.7.	Constellation BPSK	10
1.8.	Constellation QPSK	11
1.9.	Modulateur QAM	11
1.10.	Constellation 16QAM	12
1.11.	Modulation multi porteuse	13
1.12.	Interférences dues aux multi-trajets	14
1.13.	Principe du préfix cyclique	14
1.14.	Schéma de principe du démodulateur OFDM.	15
1.15.	Modèle équivalent en temps discret pour la démodulation cohérente de la FSK cohérente	16
1.16.	Modèle équivalent en temps discret pour la démodulation non-cohérente basé sur la loi carrée pour un signal FSK cohérent/non-cohérent	17
1.17.	Représentation temporelle d'un bruit gaussien et distribution statistique de son amplitude	18
1.18.	Modèle général d'un canal de transmission à bruit additif.	19
1.19.	Propagation à trajet multiple.	21

Chapitre 2

2.1.	Disposition pilote de type bloc	26
2.2.	Disposition pilote de type peigne	27
2.3.	Disposition pilote de type treillis	28
2.4.	Schéma de l'estimation du canal au sens du critère MMSE	33
2.5.	Illustration du principe des interpolations, Nearest-Neighbor et linéaire	36

Chapitre 3

3.1	Intelligence artificielle, l'apprentissage automatique et l'apprentissage en profondeur	39
3.2	Intelligence artificielle, l'apprentissage automatique et l'apprentissage en profondeur	42
3.3	Apprentissage automatique vs. Apprentissage profond	44
3.4	Différents types d'apprentissage	45
3.5	Perceptron Multicouche	47
3.6	Perceptron multicouche	49
3.7	Architecture du DNN (Le réseau pour contenir plus de couches cachées)	51
3.8	Logo Python v3.7.	52
3.9	Logo PyCharm v2018.3.4 L'architecture des Autoencoders	53
3.10	Logo de TensorFlow	54
3.11	Hiérarchie de TensorFlow	54

Chapitre 4

4.1	Schéma du système OFDM en présence d'un estimateur/détecteur DNN	57
4.2	Courbes MSE des différents estimateurs.	60
4.3	Courbes BER d'estimateur DL avec 2 différents nombres des pilotes	62

Introduction générale

Que ce soit la téléphonie, la télévision ou l'Internet, il est évident que nous sommes constamment entourés par des systèmes de communications. Cette popularité des communications nous pousse d'ailleurs à augmenter continuellement les capacités des systèmes de transmissions de l'information et c'est cette quête d'augmenter le débit de données qui constitue la motivation principale des recherches effectuées en communications.

Dans les systèmes de communications sans fil, l'environnement situé entre une antenne d'émission et une antenne de réception peut perturber le signal. En effet, le signal reçu est une somme de plusieurs versions retardées du signal émis. Les modulations à simple porteuse ne permettent pas de répondre d'une manière optimale à ces besoins, en raison de la sélectivité en fréquence des canaux et des multiples trajets que peut emprunter un même signal.

La nature des applications de futures communications sans fil nécessite des débits de données élevés et pour cette quête la technique OFDM (Orthogonal Frequency Division Multiplexing) est utilisée, les signaux OFDM génèrent des caractéristiques cyclostationnaires qui peuvent être exploitées une fois que le signal OFDM sans fil est soumis à certaines transformations non-linéaires

La répartition des symboles sur plusieurs sous porteuses est la propriété plus importante de la transmission OFDM. C'est elle qui engendre la robustesse contre le délai d'étalement et par conséquent diminue le taux de transmission par sous-porteuse.

L'estimation de canal est une partie importante de la conception de récepteurs dans les systèmes de communication mobiles. Afin de récupérer correctement les données transmises, l'effet du canal sur le signal transmis doit être évalué correctement.

L'estimation du canal joue alors un rôle clé dans les performances des systèmes de communications, elle constitue un passage obligatoire pour retrouver les symboles qui ont été émis. Le choix d'un modèle de canal est alors un point crucial. Les techniques d'estimation de canal classiques fondées sur les estimateurs LS (pour least square, ou moindres carrés) et MMSE (pour minimum mean square error, ou erreur quadratique moyenne minimum) sont souvent utilisées.

L'estimation de canal nécessite parfois une interpolation pour estimer les coefficients entre deux points connus appelés pilotes. Cependant, les interpolations créent des erreurs résiduelles ayant un impact sur la qualité de l'estimation.

La croissance du secteur des technologies de l'information et l'apparition de nouvelles technologies a suscité la nécessité aux méthodes plus récentes et plus performantes d'analyse du fonctionnement de ces systèmes. L'apprentissage profond a pris de l'importance ces derniers temps en raison de son efficacité et sa puissance. L'intelligence artificielle est une discipline scientifique recherchant à concevoir des méthodes pour résoudre des problèmes à forte complexité logique ou algorithmique. L'apprentissage automatique est un champ d'étude de l'intelligence artificielle. L'apprentissage profond (ou Deep Learning) est un ensemble de méthodes appartenant à l'apprentissage automatique qui tente de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires.

Après l'énormes succès approuvés de DL dans le domaine de télécommunications en général, et les réseaux sans fils en particulier, ça nous pousse à poser la question suivante : est ce qu'on peut exploiter les techniques avancées de l'apprentissage profond et les réseaux de neurone dans l'estimation des canaux de transmission OFDM ? et est ce qu'on peut obtenir des meilleurs résultats que les estimateurs classiques.

C'est dans ce cadre qu'est née l'idée de ce mémoire, en évaluant les performances de l'apprentissage profond dans l'estimation de canal OFDM. Pour cela, notre modeste recherche va être sur : **L'estimation du canal par apprentissage profond dans un système OFDM.**

Le mémoire est composé des quatre chapitres suivants :

Chapitre 1

Le premier chapitre introduit les éléments nécessaires pour la description d'un système de communication OFDM, en expliquant les éléments fondamentaux de la chaîne OFDM commençant par la partie d'émission et les différents types de modulation, passant par le canal de transmission et les différents modèles de canaux, en expliquant la démodulation dans la partie de réception.

Chapitre 2

Le deuxième chapitre sera consacré à l'étude de l'estimation du canal ainsi que les outils d'évaluation et de comparaison des différents estimateurs. Les différentes techniques

d'estimation de canal classiques à savoir, le critère LS (Least Squares) et le critère MMSE (Minimum Mean Squares Error).

Dans cette partie, une analyse statistique des estimateurs LS et LMMSE est étudié en parlant bien sur les outils d'évaluation et de mesure des performances (MSE et BER). On va aussi présenter les différents types d'interpolation.

Chapitre 3

Le troisième chapitre fournit une brève introduction sur l'intelligence artificielle. Depuis le commencement de ce domaine dans les années 40 avec le perceptron jusqu'aux derniers percés de nos jours,

Nous allons parler dans ce chapitre sur l'énorme intérêt de l'apprentissage profond d'une manière générale et dans les systèmes de communication sans fil en particulier, en donnant son l'architecture et le principe de son fonctionnement passant par les algorithmes utilisés pour l'apprentissage et plus particulièrement, les réseaux de neurone profonds (Deep Neural Networks).

A la fin de ce chapitre on va présenter un aperçu sur le langage de programmation Python et l'IDE PyCharm, outils qui seront utilisés dans le prochain chapitre pour effectuer la simulation.

Chapitre 4

Après avoir achevé notre partie théorique dans les trois premiers chapitres, nous avons donné les outils nécessaires pour la réalisation de notre travail. Nous avons essayé de valider les notions théoriques par des simulations réalisées avec les logiciels MATLAB et Python. En variant les différents paramètres des estimateurs et comparant les résultats obtenus des critères d'évaluation cité précisément, une analyse est présentée.

Finalement, une conclusion générale résumera le fruit de notre recherche.

Chapitre 1

Systeme de communication OFDM.

1. Introduction

Les communications numériques ont fait des progrès considérables dans les produits à grande échelle, tels que les réseaux locaux sans fil (WLAN) qui fournissent des vitesses très élevées.

Afin d'atteindre des performances élevées dans un environnement multi-trajets, ce type de réseau s'appuie sur la modulation OFDM (orthogonal Frequency Division Multiplexing), associée à la technologie de modulation de grille codée, qui permet d'augmenter le débit sans affecter la bande passante, augmentant ainsi le spectre de fréquence. Les bases théoriques du système OFDM sont connues, par contre de nombreux aspects pratiques restent à étudier. L'OFDM, qui a été proposé à la fin des années 1960, permet aux utilisateurs d'obtenir une meilleure efficacité spectrale grâce à l'orthogonalité des porteuses et au chevauchement fréquentiel des canaux.

Les techniques qu'on appelle multi porteuses consistent à transmettre des données numériques simultanément en les modulant sur un grand nombre de porteuses. Ce sont des techniques de multiplexage en fréquence qui existent depuis longtemps. Le regain d'intérêt actuel réside dans l'amélioration apportée pour augmenter l'efficacité spectrale en « orthogonalisant » les porteuses, ce qui permet d'obtenir un meilleur recouvrement spectral. L'implémentation de la modulation et de la démodulation s'effectue à l'aide de circuits performants. En résumé, l'idée principale de l'OFDM consiste à diviser la bande spectrale disponible en sous-canaux (sous-porteuses). Cette subdivision spectrale conduit à des sous canaux dont la bande de fréquence reste très faible par rapport à la bande de cohérence du canal. Ceci garantit la propriété de non sélectivité en fréquence du canal [1]

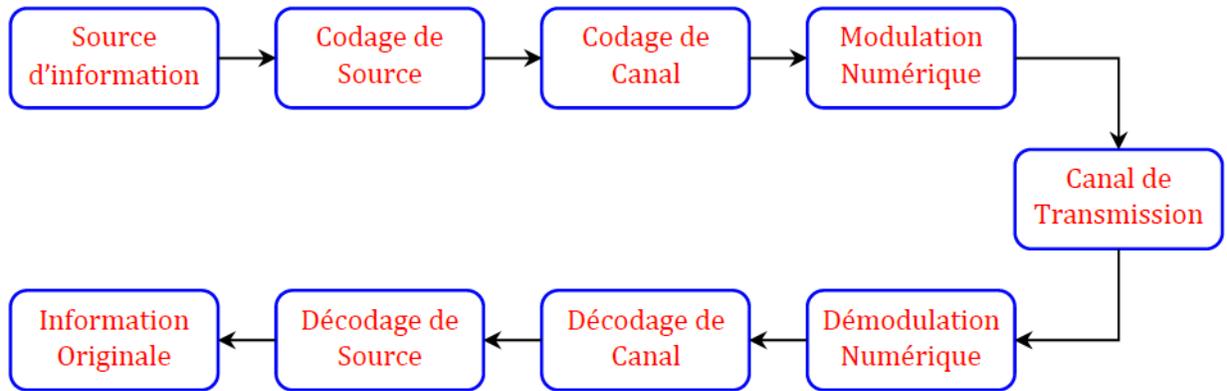


Figure 1.1 constituants de base d'une chaîne de communication numérique

2. Historique

La modulation multiporteuse est une technique de modulation utilisée dans des normes européennes telles que la radiodiffusion numérique (DAB) et la diffusion de vidéo numérique (DVB). Cette modulation a suscité beaucoup d'intérêt et a été proposée pour beaucoup d'autres applications, y compris les réseaux locaux (LAN) et les systèmes de communications personnels. Les premiers systèmes de modulation multiporteuse sont apparus dans les années 50, notamment dans les systèmes militaires HF. Les premiers schémas d'OFDM ont été présentés par Chang en 1966 et Saitzberg en 1967 [2].

L'utilisation réelle de modulation multiporteuse était limitée et l'aspect pratique du concept a été remis en question. Cependant, l'OFDM a été développé dans les travaux de Chang et Gibby en 1968 [3], Weinstein et Ebert en 1971 [4], Peled et Ruiz en 1980[5], et Hirosaki en 1981 [6], qui ont montré la possibilité de produire les opérations de modulation et de démodulation OFDM par les techniques de transformée de Fourier, ainsi que d'utiliser un préfixe cyclique pour les canaux radio-mobiles. Le choix de l'OFDM comme technique de transmission a pu être justifié par des études comparatives avec les systèmes d'une seule porteuse. En outre, une attention considérable a été portée à la combinaison de la technique de transmission d'OFDM et l'accès multiple par répartition division des codes (CDMA) dans les systèmes de canaux multiples MCCDMA par Hara et Prasad en 1997 [7]. L'OFDM est une matière de recherche pour l'usage dans les réseaux locaux sans fil et dans des applications de câble à large bande.

La modulation multiporteuse a été adoptée comme technique de modulation pour les lignes d'abonnés numériques asymétriques (ADSL, 1.536 Mb/s) [8], les lignes d'abonnés numériques

de haut débit (HDSL, 1,6 Mb/s), les lignes d'abonnés numériques de haute vitesse (VHDSL, 100 Mb/s) [9], la radiodiffusion numérique d'acoustique (DAB) et la radiodiffusion terrestre (HDTV) ainsi que pour les futurs standards de troisièmes et quatrièmes générations.

3. Techniques de modulation OFDM

L'OFDM (Orthogonal Frequency Division Multiplexing) est utilisé dans les réseaux sans fil et les réseaux cellulaires, sans oublier la tv numérique. Elle consiste à transmettre les données en parallèle sur un très grand nombre de sous-porteuses. Une telle transmission se fait simplement à partir de transformées de Fourier. [10]

4. Les différents types de technique OFDM [2]

4.1 C-OFDM (Coded - OFDM)

Offre un réel avantage en la présence de signaux d'interférence à bande étroite isolées.

4.2 V-OFDM (Vector -OFDM)

- Développé par CISCO.
- Augmente la couverture de l'abonné.
- Réduit le coût de provisionnement et le déploiement des infrastructures.
- Emploie la fréquence et la diversité spatiale.
- Crée une technique de traitement robuste pour trajets multiples et les interférences à bande étroite.

4.3 W-OFDM (Wideband OFDM)

- Inventé par Wi-LAN.
- Grand écart entre les transporteurs.

4.4 Flash-OFDM

- La technologie à étalement de spectre large bande.
- Évite les compromis inhérents à d'autres systèmes de données mobiles.

5. Notion d'orthogonalité [11]

L'orthogonalité est une caractéristique de base qui permet à plusieurs signaux d'information d'être transmis dans un seul canal et détectés sans interférence. Il y a deux types d'orthogonalité

: l'Orthogonalité temporelle et l'Orthogonalité fréquentielle. Mathématiquement, l'orthogonalité de deux fonctions $f(t)$ et $g(t)$ dans l'intervalle $[a, b]$ est définie par la relation suivante :

$$\int_a^b f(t)g(t)dt = 0 \quad (1.1)$$

6. Principe de modulation OFDM

Le principe de l'OFDM est de répartir le signal numérique à transmettre sur un grand nombre de sous-porteuses. Il semble que nous allons combiner des signaux qui doivent être transmis à des fréquences différentes sur un grand nombre de systèmes de transmission indépendants (tels que des émetteurs). Afin de rapprocher au maximum les fréquences des sous-porteuses, de manière à transmettre le maximum d'informations sur une partie fréquentielle donnée, OFDM utilise des sous-porteuses orthogonales entre elles. Les signaux des différentes sous-porteuses se chevauchent mais n'interfèrent pas les uns avec les autres en raison de l'orthogonalité. Comme le montre la figure 1.2 :

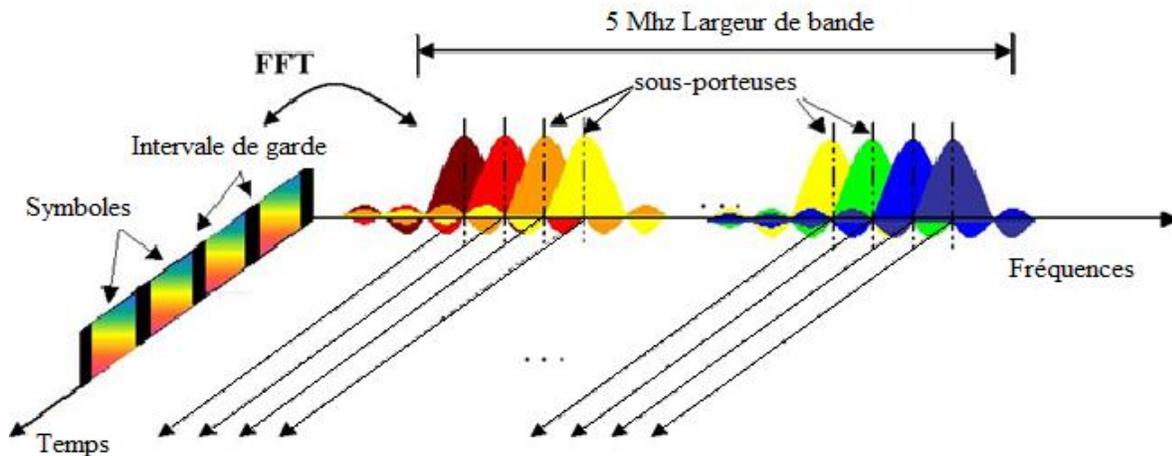


Figure 1.2 représentation temporelle et fréquence du signal OFDM

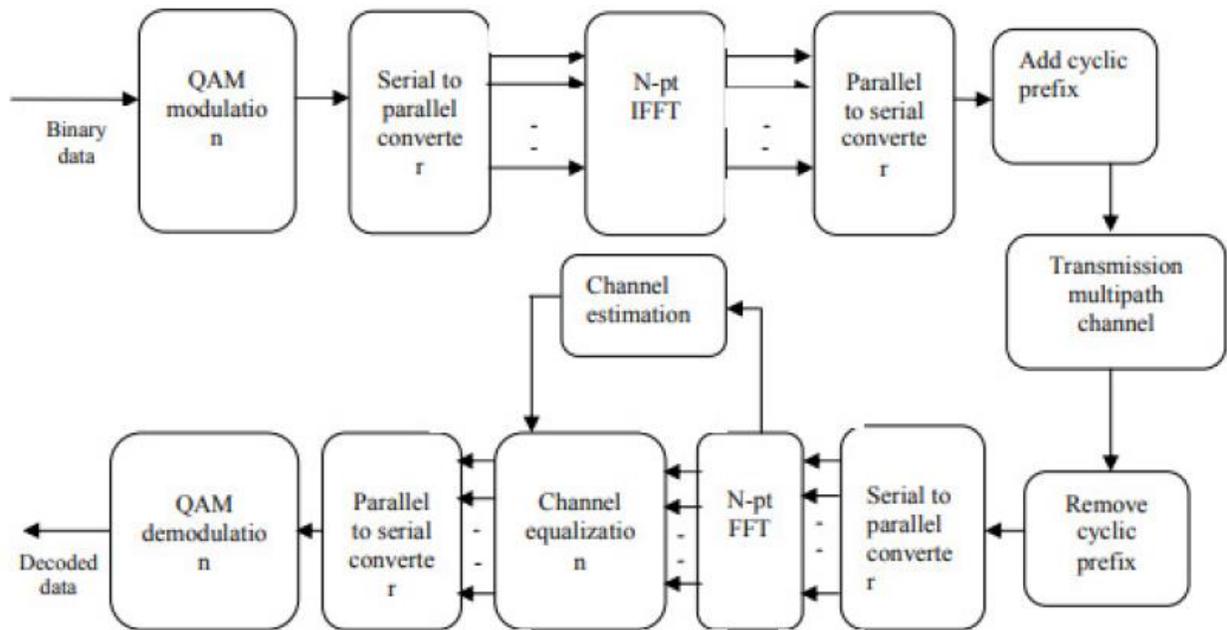


Figure 1.3 chaine de transmission OFDM

Le schéma ci-dessus illustre un système OFDM complet :

Les données binaires qui vont être transmises, passe par le bloc de modulation (QAM, PSK, M-QAM...), et démodulé utilisant le démodulateur à la réception. Après une conversion série/parallèle et parallèle/série, les blocs IFFT et FFT pour la modulation et la démodulation des sous-porteuses, Le préfixe cyclique ajouté au début du symbole et ce préfixe est identique au segment de même longueur à la fin du symbole, longueur de cet intervalle est choisie de façon à être supérieur à la valeur maximale de délai du a l'effet de trajet multiple [12]

Dans un système OFDM, les bits d'informations pour chaque sous-porteuse sont modulés par les modulations numériques telles que QPSK (Quaternary Phase Shift Keying), ou QAM. On peut augmenter le débit binaire en augmentant le nombre d'états dans une constellation, entraînant une diminution de distance entre les points de la constellation, ce qui accroît la sensibilité du système au bruit.

En général, la constellation de chaque sous-porteuse montre un changement aléatoire d'amplitude et de phase provoqué par l'environnement par trajets multiples. Parmi les modulations utilisées dans un système OFDM, la plus robuste est la modulation QPSK qui code 2 bits par symbole.

Les étapes suivantes décrivent Le principe d'un modulateur OFDM [13]

- Considérons une séquence de N données S_0, S_1, \dots, S_{N-1}
- Appelons T_s la durée symbole c'est-à-dire le temps qui sépare 2 séquences de N Données.
- Chaque donnée C_k (nombre complexe) module un signal à la fréquence f_k .
- Le signal individuel s'écrit sous forme complexe : $C_k e^{2j\pi f_k t}$
- Le signal $S(t)$ total correspondant à toutes les données d'un symbole OFDM est la somme des signaux individuels :

$$S(t) = \sum_{k=0}^{N-1} C_k e^{2j\pi f_k t} \quad (1.2)$$

- Le multiplexage est orthogonal si l'espace entre les fréquences est $1/T_s$ alors :

$$f_k = f_0 + \frac{k}{T_s} \text{ et } S(t) = e^{2j\pi f_0 t} \sum_{k=0}^{N-1} C_k e^{2j\pi \frac{kt}{T_s}} \quad (1.3)$$

Le signal parvenant au récepteur s'écrit, sur une durée symbole T_s :

$$\frac{1}{T_s} \int_0^{T_s} e^{2j\pi(k-i)\frac{t}{T_s}} dt = 0 \quad (1.4)$$

$H_K(t)$ Est la fonction de transfert du canal autour de la fréquence f_k et au temps t . Cette fonction varie lentement et on peut la supposer constante sur la période T_s ($T_s \ll 1/B_d$). La démodulation classique consisterait à démoduler le signal suivant les N sous-porteuses.

En pratique, comme pour la modulation, on remarque que la démodulation peut être réalisée par une transformée de Fourier. [2]

7. Modulations numériques

Le choix du type de la modulation numérique dépend en général de deux conditions essentielles. La première est de limiter la bande passante requise pour transmettre un message à une vitesse donnée. La deuxième est liée à la possibilité de transmettre un signal par voie hertzienne ou de partager un canal de communication. Pour le standard IEEE802.11, la modulation multiniveau d'amplitude et la démodulation cohérente sont utilisées. Ce qui suit est un rappel portant sur la modulation QPSK et MQAM avec les courbes théoriques d'erreur par bit en fonction de E_b/N_0 de ces deux types de modulation. La modulation a pour objectif d'adapter le signal à émettre au

canal de transmission. Cette opération consiste à modifier un ou plusieurs paramètres d'une onde porteuse. Les paramètres modifiables sont : L'amplitude, la fréquence et la phase. Dans les procédés de modulation binaire, l'information est transmise à l'aide d'un paramètre qui prend deux valeurs possibles. Dans les procédés de modulation M-aire, le paramètre prend M valeurs. Ceci permet d'associer à un état de modulation un mot de n digits, ce qui correspond à un nombre d'états de $M=2^n$, Ces n digits proviennent du découpage en paquets de n digits du train binaire issu d'un codeur [14].

- Un symbole est un élément d'un alphabet. Si M est la taille de l'alphabet, le symbole est alors dit M-aire. Lorsque $M=2$, le symbole est dit binaire.
- La rapidité de modulation R : $R=\frac{1}{T}$ elle s'exprime en bauds.
- Le débit binaire D se définit comme étant le nombre de bits transmis par seconde. $D=nR=\frac{1}{Tb}$ (durée d'un bit).
- L'efficacité spectrale d'une modulation se définit par le paramètre $\eta=\frac{D}{B}$ B, est la largeur de la bande occupée par le signal modulé. Pour un signal utilisant des symboles Maires, on aura $\eta=\frac{1}{T.B}\log_2(M)$
- Pour B et T donnés, l'efficacité spectrale augmente, comme on pouvait s'y attendre, avec le nombre de bit/symbole $n=\log_2(M)$. C'est en effet la raison de la modulation M-aire.
- Le message à transmettre est issu d'une source binaire. Le signal modulant, obtenu après codage, est un signal en bande de base, éventuellement complexe, qui s'écrit sous la forme :

$$C(t) = \sum_k C_k \cdot g(t - kT) \quad \text{avec } C_k = a_k + j b_k \quad (1.5)$$

- La modulation transforme ce signal $c(t)$ en un signal modulé $m(t)$ tel que :

$$M(t) = \text{Re} \left[\sum_k C_k \cdot e^{j(\omega_0 t + \phi_0)} \right] \quad (1.6)$$

$\omega_0 t, \phi_0$: pulsation et phase de la porteuse.

Dans la suite on va présenter les principaux types de modulations numériques.

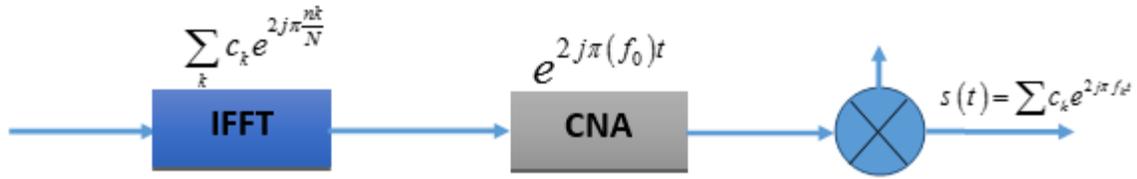


Figure 1.4 Schéma de modulation OFDM

7.1. Modulation ASK

La technique de modulation numérique la plus simple est le déplacement d'amplitude (Amplitude Shift Keying), où un signal d'information binaire directement module l'amplitude d'une porteuse analogique. Cette modulation est parfois appelée modulation d'amplitude numérique [15]. Mathématiquement, la modulation par déplacement d'amplitude est :

$$v_{ask}(t) = [1 + v_m(t)] \left[\frac{A}{2} \cos(\omega c t) \right] \quad (1.7)$$

- $v_{ask(t)}$ == Onde du signal modulé.
- $v_m(t)$ = Signal d'information numérique (modulant) (volts).
- $A / 2$ = amplitude de la porteuse non modulée (volts).
- ωc = fréquence radian porteuse analogique.

Dans l'équation (1.7), le signal de modulation [$v_m(t)$] est une forme d'onde binaire normalisée, où $+1$ V = 1 logique et -1 V = 0 logique. Par conséquent, pour une entrée logique 1, $v_m(t) = +1$ V, Equation (1.7) réduit à :

$$v_{ask} = [1 + v_m(t)] \left[\frac{A}{2} \cos(\omega c t) \right] = A \cos(\omega c t) \quad (1.8)$$

Et pour une entrée logique 0, $v_m(t) = -1$ V. l'équation (1.8) se réduit à :

$$v_{ask}(t) = [1 - 1] \left[\frac{A}{2} \cos(\omega c t) \right] \quad (1.9)$$

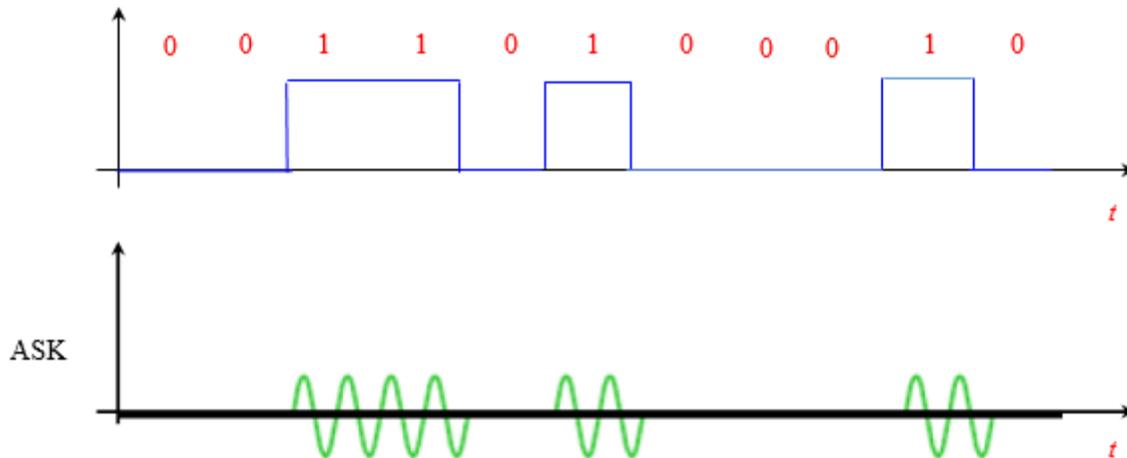


Figure 1.5 modulation d'amplitude ASK.

7.2. La Modulation FSK

La modulation par déplacement de fréquence est une forme de modulation d'angle à amplitude constante similaire à la modulation de fréquence standard (FM) sauf le signal modulant est un signal binaire qui varie entre deux niveaux de tension discrets plutôt que d'un changement continu forme d'onde analogique [15]. Par conséquent, FSK est parfois appelé FSK binaire (BFSK). L'expression générale pour FSK est :

$$v_{FSK}(t) = v_c(t) \cos(\omega ct) \left\{ 2\pi [f_c + v_m(t) \Delta f] t \right\} \quad (1.10)$$

- $v_{FSK}(t)$ = forme d'onde FSK binaire.
- $v_c(t)$ = amplitude porteuse analogique maximale (volts).
- f_c = fréquence centrale porteuse analogique (hertz).
- Δf = changement de crête (décalage) dans la fréquence porteuse analogique.
- $v_m(t)$ = signal d'entrée binaire (modulant) (volts).

À partir de l'équation 1.10, on peut voir que le changement de la fréquence porteuse (Δf) est proportionnel à l'amplitude de signal d'entrée binaire ($v_m(t)$), et la direction du décalage est déterminée par la polarité. Le signal de modulation est une forme d'onde binaire normalisée logique 1 = + 1 V et une logique 0 = -1 V. Ainsi, pour une entrée logique $v_m(t) = + 1$, l'équation 1.10 peut être réécrite comme :

$$v_{FSK}(t) = v_c(t) \cos(\omega_c t) \{2\pi [f_c + \Delta f] t\} \quad (1.11)$$

Pour une entrée logique 0, $v_m(t) = -1$ l'équation 1.11 devient :

$$v_{FSK}(t) = v_c(t) \cos(\omega_c t) \{2\pi [f_c - \Delta f] t\} \quad (1.12)$$

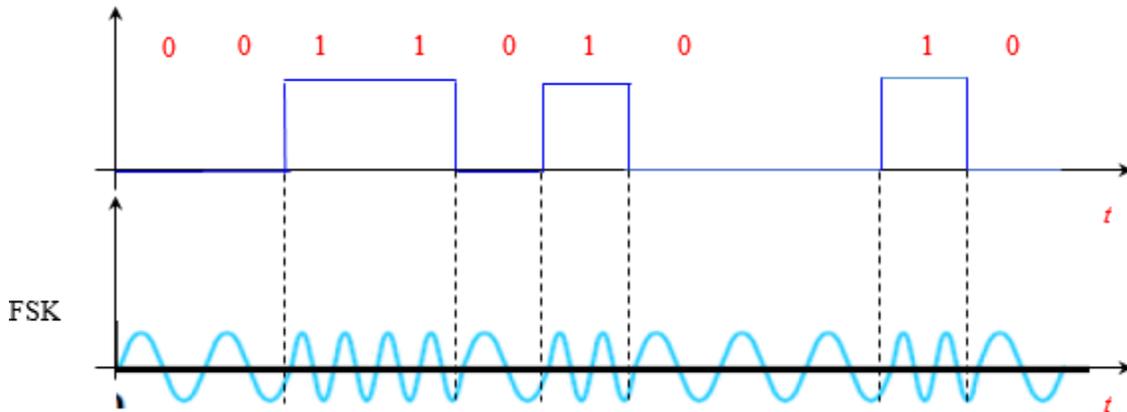


Figure 1.6 modulation de fréquence FSK

7.3. La modulation PSK

Un exemple de la modulation numérique par déplacement de phase est la modulation binaire dite BPSK (Binary Phase Shift Keying), c'est une modulation de phase à 2 états 0 et π . Dans la constellation, il n'y a que 2 points, un à 0° qui correspond au niveau logique 1 et un autre à 180° qui correspond au niveau logique 0 [16]

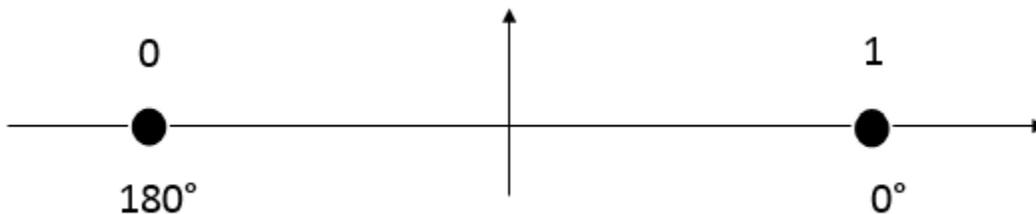


Figure 1.7 Constellation BPSK

Un autre type de modulation numérique de phase est la PSK en quadrature ou (QPSK). Le train de donnée binaire est séparé en deux "sous trains" appelés le composant cosinus (**I** ou In-phase) et le composant sinus (**Q** ou Quadrature). La paire de valeur (ou doublet) constitue ce que

l'on appelle un symbole. Pour des considérations électroniques, les signaux **I** et **Q** sont centrés sur 0V. On peut donc considérer que **I** et **Q** prennent symboliquement deux niveaux +1, -1 correspondant aux états binaires [16].

L'état de phases du signal modulé se représentent en coordonnées polaires dans le plan **I, Q**. Suivant les combinaisons de **I** et **Q**, on obtient alors un diagramme que l'on appelle communément constellation. Le schéma ci-dessous montre les constellations de la modulation QPSK (Quadrature Phase Shift Keying) [16].

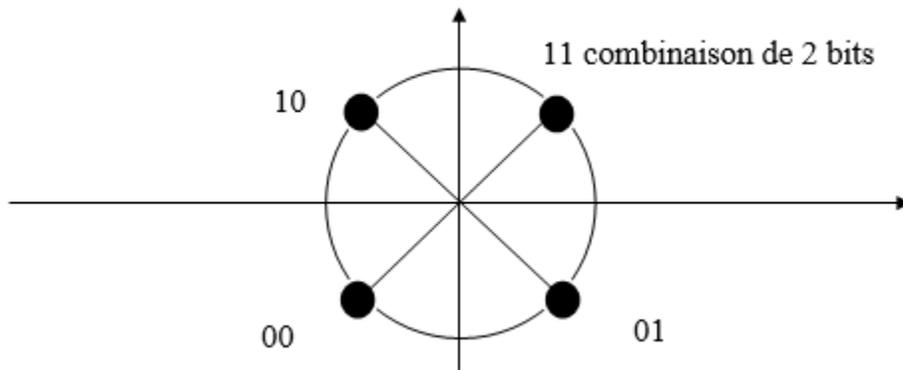


Figure I.8 constellation QPSK

7.4. La modulation QAM

La QAM ou Modulation d'amplitude en quadrature résulte de la combinaison de deux fréquences porteuses sinusoïdales déphasées l'une de l'autre de 90° (d'où le nom de quadrature). Elle peut aussi être vue comme une modulation de phase et d'amplitude, elle permet des débits élevés [17].

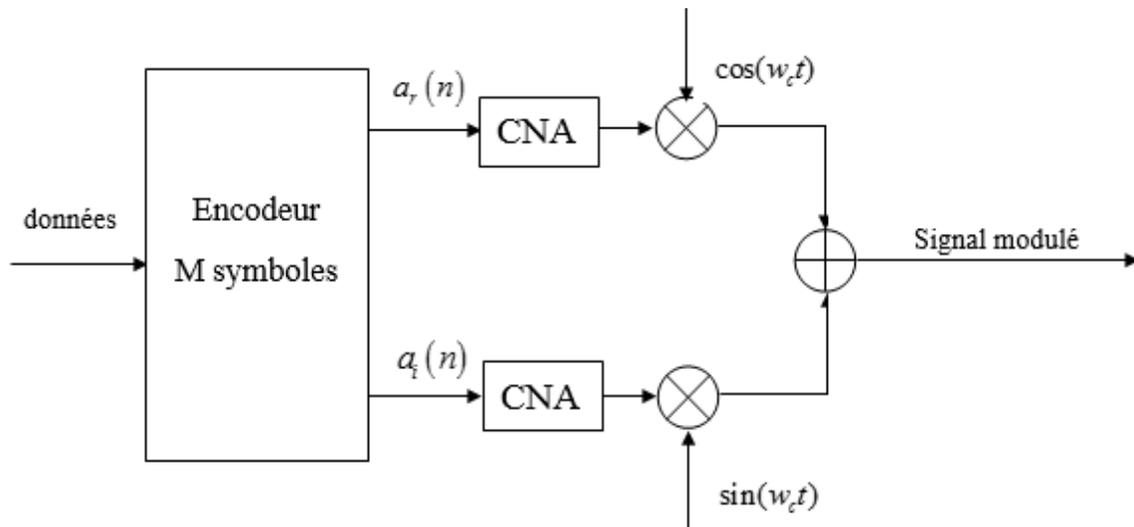


Figure 1.9 modulateur QAM

Un exemple de la modulation QAM est la modulation QAM à seize états. La 16 QAM utilise 4 bits par symbole, 2 bits sur i et deux bits sur Q . La valeur de i peut être une des 4 amplitudes possibles. Il en est de même pour la valeur de Q . La constellation comporte 16 points ($2^4=16$) [16].

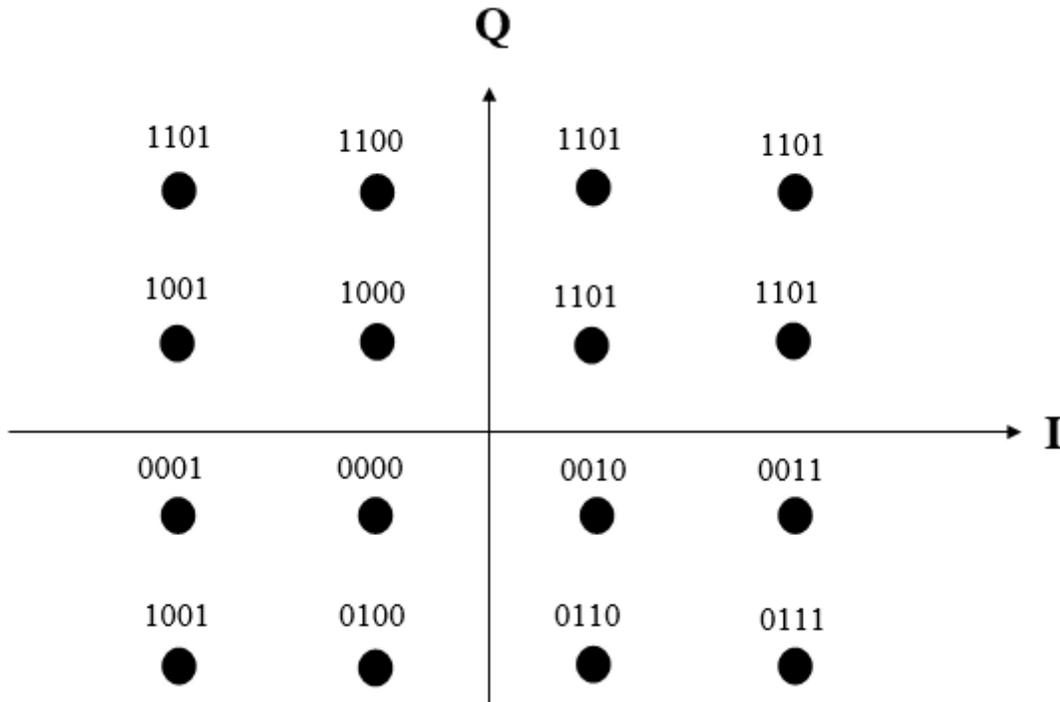


Figure 1.10 constellation 16QAM

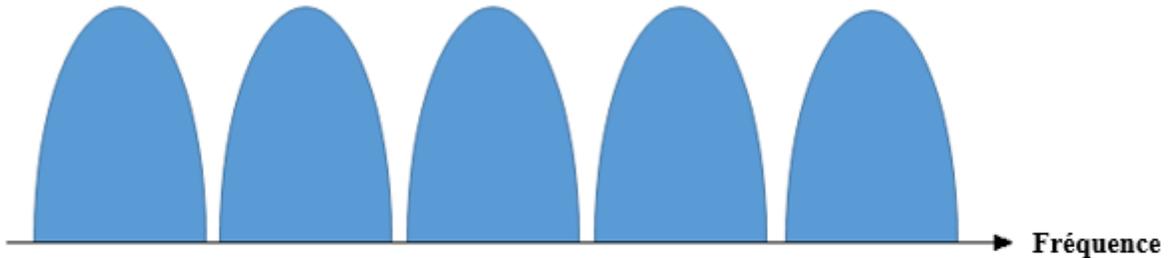
Le principal avantage des technologies de modulation numérique est qu'elles peuvent s'insérer harmonieusement dans le réseau numérique intégré en constante évolution. Un autre avantage est que l'intégrité des informations à transmettre peut-être maintenue, ce qui est totalement impossible pour une transmission analogique. Les systèmes de communication numérique modernes sont très complexes et nécessitent des circuits de modulation et de démodulation de plus en plus complexes.

7.5. Modulation multi porteuse

Les techniques qu'on appelle multi-porteuses consistent à transmettre des données numériques en les modulant sur un grand nombre de porteuses en même temps. Ce sont des techniques de

multiplexage en fréquence qui existent depuis longtemps. L'implémentation de la modulation et de la démodulation se fait à l'aide de la transformée de Fourier rapide FFT (Fast Fourier Transform) [18].

Multiporteuse



Monoporteuse



Figure 1.11 modulation FDM

La formulation d'un signal multi-porteur est réalisée par l'équation (1.13) :

En notant : $[n] = [m + nM]$:

$$s(t) = \sum_{n=-\infty}^{+\infty} \sum_{m=0}^{M-1} x_m[n] \gamma_{m,n}(t) \tag{1.13}$$

Base de formes d'onde modulantes : $\{\gamma_{m,n}(t), (m,n) \in \mathbb{Z}^2\}$

M : le nombre de fréquences porteuses.

8. Concept du CP

Du fait du multi trajets, les différentes répliques du signal OFDM arrivent au niveau du récepteur avec des délais différents, ce qui cause la dispersion du délai multi trajets. De plus, en pratique l'orthogonalité entre les différentes sous porteuses est perdue sur un canal sélectif, qui cause une interférence inter symboles (ISI) et une interférence inter porteuses (ICI)

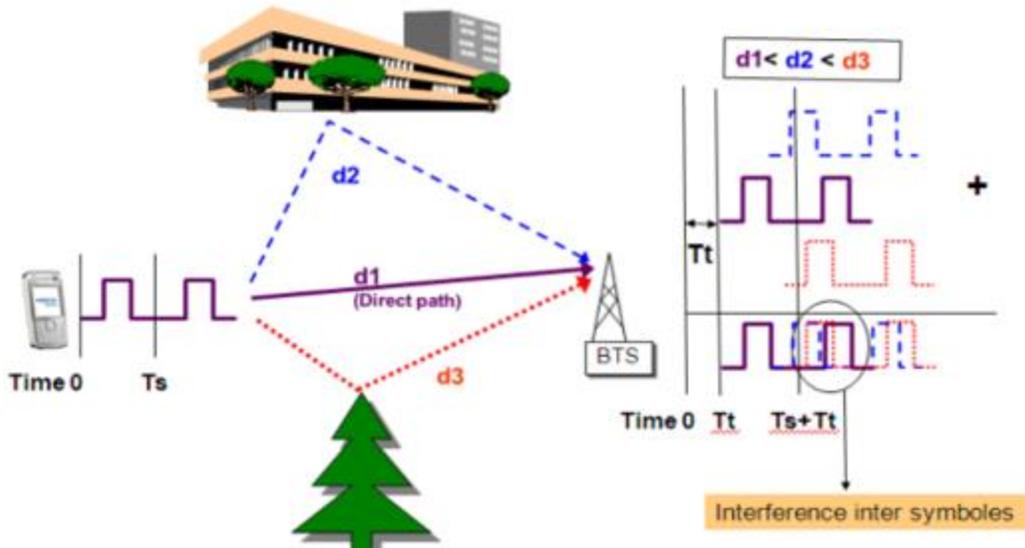


Figure 1.12 Interférences dues aux multi-trajets

Afin de minimiser ces effets, le concept du préfix cyclique (CP) est adopté. Le CP est une copie d'une portion de la fin du symbole OFDM, à transmettre, qui est ajoutée au début du symbole (figure I.13). Cet intervalle dit "de garde" est enlevé au niveau du récepteur avant la démodulation.

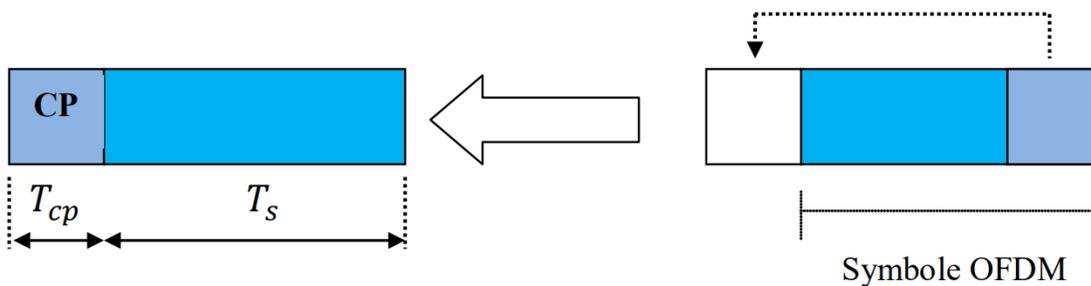


Figure 1.13 Principe du préfix cyclique

$$T_c = T_s + T_{cp}$$

T_c Est la durée du symbole transmis.

T_s est la durée du symbole.

T_{cp} est la longueur du CP.

Sur la figure I.13, on remarque qu'il ya deux type de CP, normal et étendu. Dans le cas du CP normal, le premier slot des symboles OFDM est plus large que les autres. Les longueurs du CP

sont définies comme suite : $T_{cp} = 160T_s = 5.1\mu s$ pour le premier symbole et $T_{cp} = 144T_s = 4.7\mu s$ pour les symboles OFDM restants. $T_{cp-e} = 160T_s = 16.7\mu s$. [19]

9. Principe de démodulation

Le signal parvenu au récepteur s'écrit sur une durée symbole T_s [20]:

$$y(t) = \sum_{k=0}^{N-1} c_k H(t) e^{2j\left(f_0 + \frac{k}{T_s}\right)t} \quad (1.14)$$

$H_k(t)$ est la fonction de transfert du canal autour de la fréquence f_k et à l'instant t . Cette fonction varie lentement et on peut la supposer constante sur la période T_s ($T_s \ll 1/B_d$). La démodulation classique consisterait à démoduler le signal suivant les N sous-porteuses suivant le schéma classique

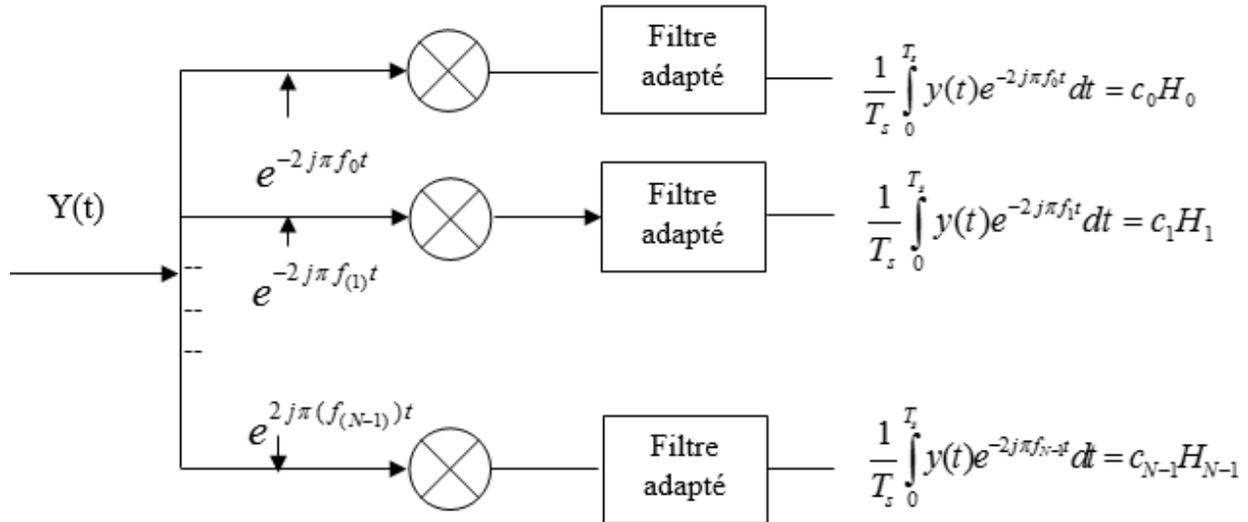


Figure 1.14 Schéma de principe du modulateur et démodulateur OFDM.

10. Démodulation cohérente et non-cohérente

10.1. Démodulateur cohérent

Il existe toujours un signal FSK cohérent et le démodulateur basé sur un oscillateur contrôlé par tension (VCO) est le plus populaire d'entre eux. Le démodulateur cohérent pour FSK peut également être implémenté en utilisant uniquement un corrélateur, et son modèle équivalent à temps discret est présenté dans la figure 1.15 Ici, le démodulateur nécessite les informations de phase initiale ($\varphi_1 = \varphi_2 = \varphi$) qui ont été utilisées pour générer le signal FSK cohérent au niveau

de l'émetteur. Si ces informations de phase ne sont pas connues avec précision au niveau du récepteur, le démodulateur échoue complètement. Afin d'éviter la récupération de phase de la porteuse, un démodulateur non cohérent peut être utilisé pour démoduler un signal FSK cohérent, mais il y a une pénalité de performance de taux d'erreur en le faisant (voir la section suivante). [21]

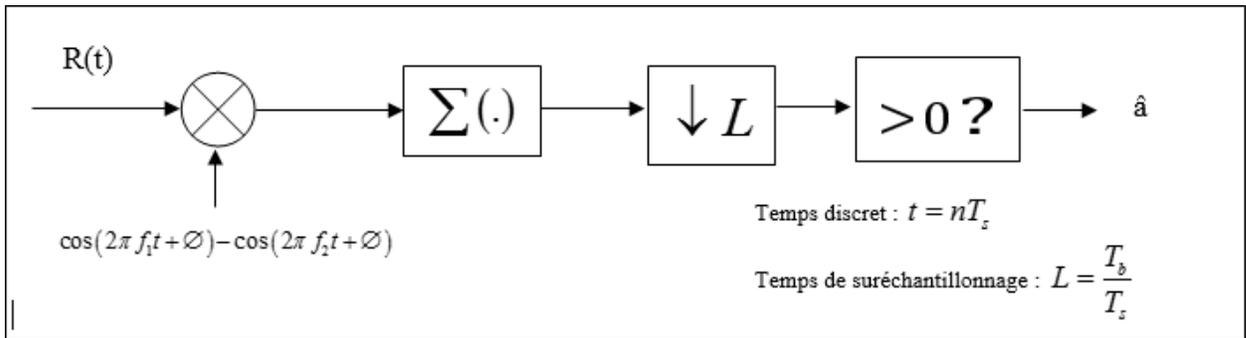


Figure 1.15 modèle équivalent en temps discret pour la démodulation cohérente de la FSK cohérent

10.2. Démodulateur Non-coherent

Un démodulateur FSK non cohérent ne se soucie pas des informations de phase initiale utilisées à l'émetteur, évitant ainsi la nécessité d'une récupération de la phase porteuse au récepteur. En conséquence, le démodulateur non cohérent est plus facile à construire et offre donc une meilleure solution pour les applications pratiques.

Le modèle équivalent temps discret pour un démodulateur non cohérent fondé sur un corrélateur/loi carrée est illustré à la figure 1.16. Il peut être utilisé pour démoduler à la fois le FSK cohérent et le signal FSK non cohérent [21].

La probabilité théorique d'erreur binaire du FSK binaire détecté non-cohérente sur le bruit AWGN, ou deux signaux porteurs sont orthogonaux et équiprobables, est donné par [21]:

$$P_b = \frac{1}{2} e^{E_b/(2N_0)} \quad (1.15)$$

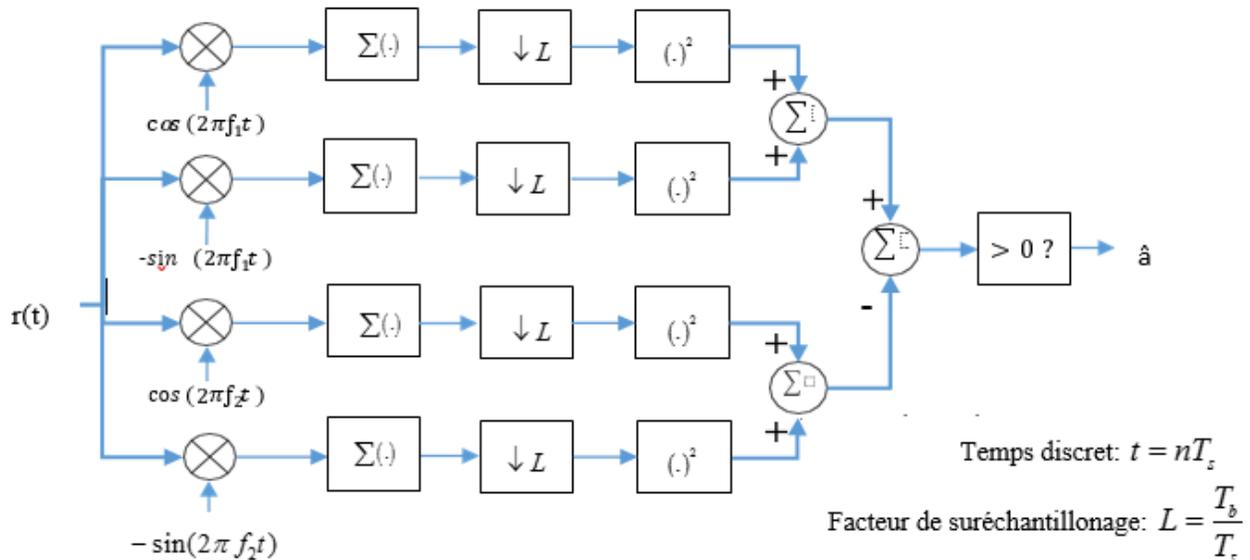


Figure 1.16 Modèle équivalents en temps discret pour la démodulation non cohérente basé sur la loi carrée pour un signal FSK cohérent/non-cohérent

11. Canal de transmission

Le canal de transmission est le support physique utilisé pour transmettre les informations de l'émetteur au récepteur, et il varie selon le type d'application envisagée. Ainsi, si le téléphone utilise des câbles bifilaires, davantage d'applications à haut débit privilégieront les câbles coaxiaux, permettant des débits de l'ordre du Mbit/s, ou mieux encore, des fibres optiques pouvant supporter des débits de plusieurs Gbit/s. Dans le cadre de nos travaux, nous considérerons plutôt la transmission de signaux à haut débit (signal OFDM), qui utilise des ondes électromagnétiques pour se propager dans l'espace lib. Quel que soit le support utilisé dans le processus de propagation du signal, il sera affecté par diverses dégradations. Les sources, telles que les évanouissements spécifiques à la propagation, les bruits thermiques générés par les équipements électroniques ou encore les interférences électriques dues aux interférences, parasites, foudre, etc.

12. Modèles de canaux de transmission

Une transmission d'information se fait toujours à distance, un support physique assure le lien entre la source et le destinataire dans cette partie, nous allons présenter les principaux canaux de transmission couramment utilisés comme média de communications.

12.1. Canal a bruit additif gaussien

Le bruit blanc gaussien est un modèle de bruit largement utilisé dans de nombreux domaines. En effet, lorsqu'un phénomène correspond à la somme d'un grand nombre de variables aléatoires, il est possible de démontrer par le théorème de la limite centrale que la distribution statistique de ce phénomène suit une distribution gaussienne. Dans le domaine fréquentiel, un bruit blanc présente une DSP (Densité Spectrale de Puissance) constante en fonction de la fréquence. Un bruit gaussien suit une distribution gaussienne, caractérisée par une moyenne μ et une variance σ^2 . La densité de probabilité est donnée par l'équation 1.16. La représentation temporelle d'un bruit gaussien ainsi que la distribution statistique de son amplitude qui suit une distribution gaussienne sont données à la figure 1.17. La représentation temporelle ne permet pas d'extraire d'informations sur le signal en raison de sa nature aléatoire, mais la distribution permet d'extraire des éléments statistiques sur la nature du bruit [21].

La densité de probabilité est donnée par :

$$f(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{z-\mu}{\sigma}\right)^2} \quad (\text{I.16})$$

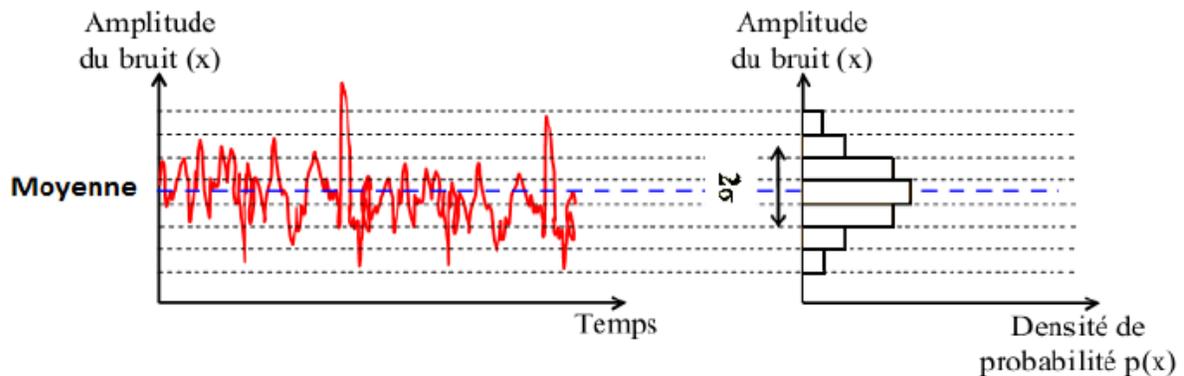


Figure 1.17 Représentation temporelle d'un bruit gaussien et distribution statistique de son amplitude.

Un canal AWGN (Additive White Gaussian Noise), est non discret et sans mémoire qui représente parfaitement une liaison radio en vue directe dont le bruit est principalement d'origine thermique. Le bruit additif est dans ce cas un bruit gaussien de moyenne nulle et de variance σ^2 . Comme il s'agit d'un bruit blanc, la densité spectrale de bruit est constante avec la fréquence, ce qui représente une hypothèse simplificatrice des calculs qui reste valide si on considère des bandes de fréquence étroites. La figure 1.18 illustre le modèle général d'un canal AWGN. Le

canal est caractérisé par une fonction de transfert ou une réponse impulsionnelle, qui décrivent le comportement soit fréquentiel soit temporel du canal. Les perturbations externes et le bruit se couplent au canal et sont ajoutés au signal transmis.

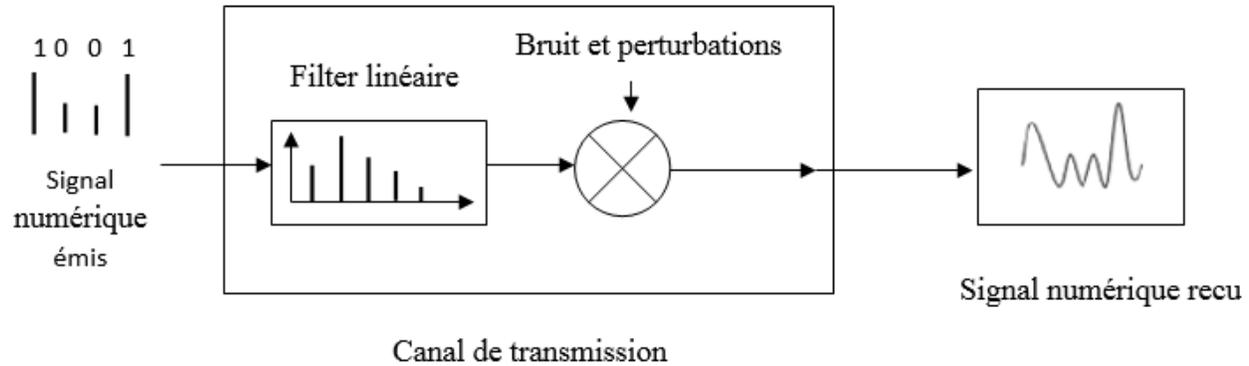


Figure 1.18 Modèle général d'un canal de transmission à bruit additif

12.2. Canal de Rayleigh

Dans les liaisons radio-mobiles, les canaux de transmission évoluent en fonction du temps à cause des déplacements aléatoires des entités communicantes et l'existence d'obstacles entre l'émetteur et le récepteur. Il peut en résulter que le signal émis suit plusieurs trajets avant d'arriver au récepteur, conduisant à une variabilité importante du signal reçu due à l'addition de plusieurs signaux déphasés lorsque le débit de transmission est suffisamment faible, chaque symbole ne se superpose qu'avec lui-même, au moins sur une portion significative de Sa durée un canal de Rayleigh permet de prendre en compte ces effets : réflexions multiples, évanouissements, fluctuations à grande et petite échelle et effet Doppler. L'amplitude et la Phase du signal reçu apparaissent comme des variables aléatoires qui suivent une loi de Rayleigh exprimée par l'équation (1.17) [23]. Ce modèle est particulièrement adapté à une représentation statistique d'un canal radio- mobile :

$$p(x) = \frac{x^2}{\delta} e^{-\left(\frac{x^2}{2\delta^2}\right)} \quad (I.17)$$

13. Les phénomènes perturbateurs dans les systèmes de communications

13.1. Le Bruit

Dans tous systèmes de communication, il y a toujours une présence de bruit introduite. Ce dernier consiste en des signaux parasites qui se superposent au signal et qui donnent, en définitive, un signal déformé.

Les sources de bruit sont classées en deux catégories essentielles. Les sources de bruit situées à l'extérieur du système de traitement et les sources de bruit interne au système, créant un bruit propre indépendant des conditions extérieures.

13.2. Propagation Multi-trajet

Les trajets multiples sont engendrés par les phénomènes physiques propres aux ondes Électromagnétiques tels que la réflexion et la diffraction causées par le milieu de propagation (immeubles, collines, voitures, ...), comme le montre le scénario présenté sur la figure 1.19, le nombre de trajets empruntés par un même signal peut être important, mais dans la modélisation du canal, seuls les trajets significatifs sont pris en compte ainsi, pour un canal comportant L trajets significatifs, le récepteur reçoit L répliques du signal émis provenant de diverses directions avec des retards, des atténuations et des phases propres.

Les différents retards sont calculés par rapport au premier trajet détecté par le récepteur l'échantillon du signal reçu r_k peuvent alors s'écrire comme la somme des échantillons d'un même signal émis, suivant L chemins différents, avec des échantillons de bruit blanc additif gaussien comme exprime l'équation suivante [24] :

$$r_k = \sum_{i=0}^{L-1} (h_{k,i} x_{k-L} + w_k) \quad (\text{I.18})$$

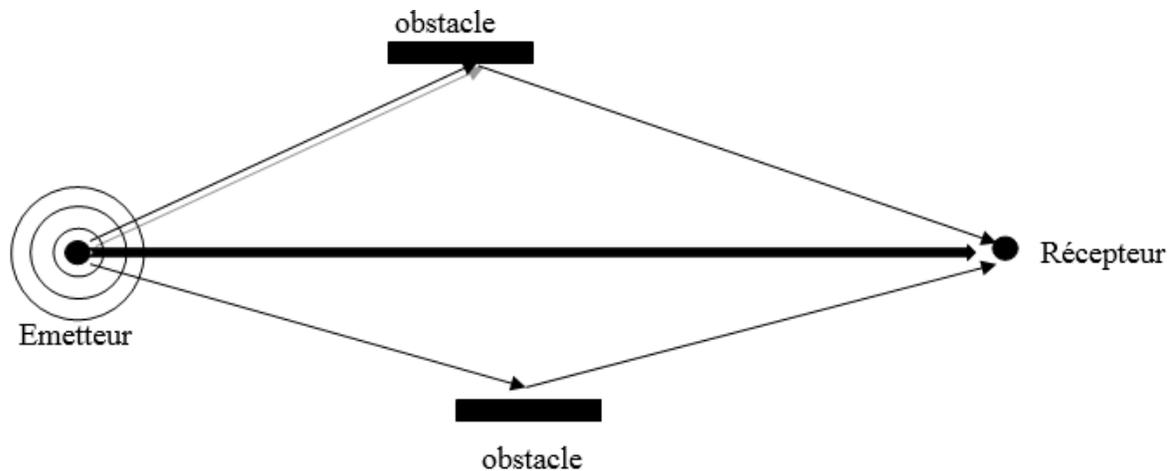


Figure 1.19 Propagation à trajets multiples.

14. Avantages et inconvénients de l'OFDM

OFDM a été utilisé dans de nombreux systèmes sans fil haut débit en raison des nombreux avantages qu'elle offre. On va citer quelques-uns :

14.1. Résistance aux interférences

Les interférences apparaissant sur le signal peuvent être limitées par la bande passante, elles n'affecteront donc pas toutes les sous-chaînes. Cela signifie que toutes les données seront perdues.

14.2. L'efficacité du spectre

Un important avantage OFDM est qu'elle permet d'utiliser efficacement le spectre disponible.

14.3. Résistant à l'ISI

Un autre avantage de l'OFDM est qu'il est très résistant aux inter-symboles et aux interférences. Ceci est dû au faible débit de données sur chaque sous-canal. Effet anti-bande étroite : en utilisant un entrelacement et un codage de canaux appropriés, les symboles perdus en raison de la sélectivité des canaux et des interférences à bande étroite peuvent être récupérés. Toutes les données ne seront pas perdues.

14.4. L'égalisation du canal plus simple

L'un des problèmes avec les systèmes CDMA était la complexité de l'égalisation du canal qui de varier être appliqués dans l'ensemble du canal. Un avantage de l'OFDM est que le recours à de multiples sous-canaux, l'égalisation du canal devient beaucoup plus simple.

Le système utilisant la technique d'OFDM n'est pas parfait, il a des inconvénients qu'il faut prendre en considération en faisant la conception et surtout au niveau de sa mise en œuvre matérielle.[25].

- L'OFDM est plus sensible au décalage de fréquence et au bruit de phase.
- Il représente le changement d'amplitude sur un intervalle dynamique assez large. Cela nécessite un amplificateur de puissance radiofréquence avec un rapport de puissance de crête relativement élevé.

15. Conclusion

Nous avons présenté dans ce chapitre les éléments nécessaires pour la description d'un système de communication OFDM. En partant des différents types de modulation, les techniques de base de modulation numérique telles qu'ASK PSK QAM et FSK', avec leurs principales caractéristiques. Le principe de base de la modulation OFDM ont été expliqué.

Nous avons également examiné le système de transmission avec Les différents modèles des canaux de transmission les plus rencontrés en pratique comme : ' Canal a bruit additive gaussien AWGN et Canal de Rayleigh 'en ajoutant les Avantages et inconvénients de l'OFDM.

Donc on peut dire que La technique OFDM présente un énorme intérêt dans les canaux multi trajets.

Cette modeste recherche nous ouvre les portes sur une étape très importante dans les systèmes OFDM qui est l'estimation de canal. C'est ça ce qu'on va voir dans le deuxième chapitre qui s'agit principalement de l'estimation du canal ainsi que les outils d'évaluation et de comparaison des différents estimateurs.

Chapitre 2

Estimation classique du canal

1. Introduction

Dans un système de communication sans fil, le canal de transmission entre l'antenne émettrice et l'antenne réceptrice est la principale source d'interférence de signal. La modulation multiporteuse, telle que l'OFDM (utilisée pour le multiplexage par répartition orthogonale de la fréquence), est très résistante aux effets de trajets multiples, et lorsqu'elles sont combinées avec le codage de canal, des transmissions de faibles taux d'erreur peuvent être réalisés. Toutefois, l'estimation de canal joue un rôle clé dans la performance des systèmes de communication

La réponse impulsionnelle d'un canal de communication peut varier considérablement d'un symbole OFDM à un autre. Dans le cas de fluctuations rapides du canal, la fonction de transfert peut subir le même changement important au sein d'un seul symbole OFDM. Par conséquent, l'estimation de canal dynamique devient une étape nécessaire pour assurer une démodulation correcte des symboles OFDM. Dans ce chapitre, nous étudierons l'estimation basée sur les techniques LS (pour Least Squares ou moindres carrés) et MMSE (pour minimum mean square error ou erreur quadratique moyenne minimale). La technique MMSE offre les meilleures performances par rapport à la technique LS, mais au détriment d'une augmentation de la complexité.

Les techniques LS et MMSE sont des techniques supervisées, c.-à-d. basées sur l'insertion périodique des signaux dits pilotes soit au niveau de toutes les sous porteuses (type bloc), ou bien à l'intérieur d'un même symbole OFDM (type peigne).

Finalement, notons que les outils d'évaluation et de comparaison des différents estimateurs sont basés sur les critères MSE (Mean Square Error) et BER (Bit Error Rate). Le premier critère s'intéresse à la comparaison du canal estimé avec le canal réel utilisé, tandis que le deuxième critère mesure la qualité de transmission après l'utilisation de chacun des estimateurs.

2. Techniques d'estimation

Selon la technique utilisée lors de l'insertion des pilotes, les méthodes d'estimation peuvent être catégorisées comme suit :

- Les techniques aveugle.
- Les techniques non-aveugle.
- Les techniques semi-aveugle.

Les techniques aveugles peuvent faire l'estimation sans faire appel aux symboles pilotes, permettant ainsi d'augmenter le débit utile, mais manquent de robustesse. Le but de l'estimation semi-aveugle est d'exploiter l'information aveugle (signal reçu ou observé) et l'information provenant des symboles pilotes connus (la séquence d'apprentissage). Les techniques semi-aveugles robustifient le problème aveugle et permettent d'estimer des réponses impulsionnelles plus longues que celles permises en apprentissage. Pour une qualité d'estimation acceptable, elles permettent l'utilisation de séquences d'apprentissages plus courtes. De plus, elles offrent de meilleures performances d'estimations que les méthodes aveugles et non-aveugles [26].

3. Les pilotes

On appelle les méthodes semi-aveugles, ou assistées par pilotes celles qui utilisent des porteuses dites « pilote » pour effectuer l'estimation. Les pilotes sont des porteuses dont le gain, la phase et la position dans la trame OFDM sont connus de l'émetteur et du récepteur. Le motif des pilotes dans la trame OFDM dépend de la sélectivité du canal [27]. Ainsi, pour un canal très sélectif en fréquence mais pas en temps, on utilisera un arrangement de pilotes dans le domaine fréquentiel, ou chaque sous porteuse d'un symbole OFDM donné est dédié à l'estimation. C'est le motif utilisé quand on considère un canal quasi-statique. Pour un canal moyennement sélectif en fréquence, mais très sélectif en temps, on utilisera plutôt un arrangement dans le domaine temporel, ou certaines fréquences sont exclusivement dédiées à l'estimation de canal.

Pour chaque symbole OFDM, on a deux dispositions : les porteuses pilotes et les porteuses d'information. Selon la sélectivité des canaux considérés, d'autres motifs peuvent être utilisés : dans le standard DRM/DRM+ [28], les pilotes sont disposés en quinconce, un motif rectangulaire, hexagonal ou une disposition aléatoire peuvent aussi être considérés [29]. Si le canal est bien estimé au niveau des positions pilotes, une interpolation sera nécessaire pour estimer la réponse fréquentielle du canal sur tout le réseau temps-fréquence. Certaines méthodes d'estimations vont être abordées par la suite.

3.1. Structure des pilotes

Selon la structuration de la trame OFDM en présence des symboles pilotes, trois différentes configurations sont considérées :

- Configuration en bloc
- Configuration en peigne
- Configuration en treillis

3.1.1. Configuration en bloc

La configuration en bloc est représentée sur la **Figure 2.1**. Dans ce type, les symboles OFDM avec les pilotes dans tous les sous-porteuses (appelé ici, symbole de pilote) sont transmis périodiquement pour l'estimation de canal. En utilisant ces pilotes, une interpolation de temps est effectuée pour estimer le canal le long de l'axe du temps.

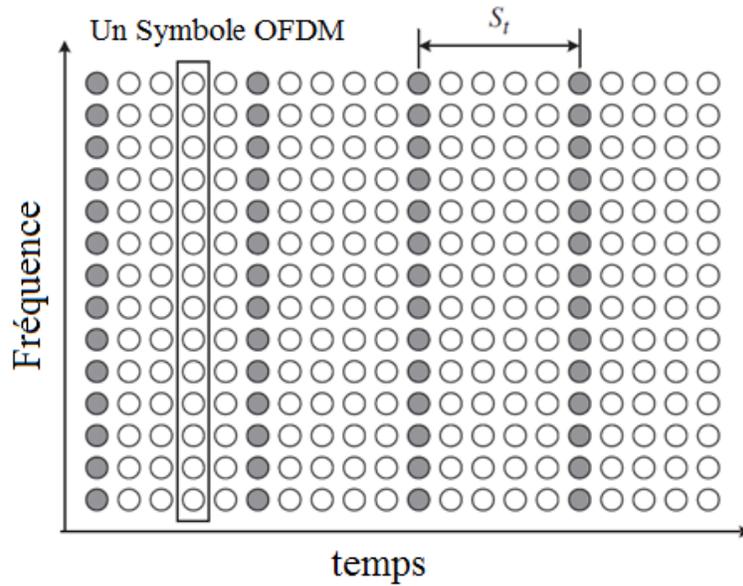


Figure 2.1 Disposition pilote de type bloc

Soit S_t la période des symboles pilotes dans le temps, afin de garder une trace des caractéristiques de la variation du canal en temps, les symboles pilotes doivent être aussi fréquents que le temps de cohérence. Puisque le temps de cohérence est donné par l'inverse de la fréquence de doppler, $f_{Doppler}$, dans le canal, la période des symboles pilote doit satisfaire l'inégalité suivante :

$$S_t \leq \frac{1}{f_{Doppler}} \quad (2.1)$$

Puisque les symboles sont utilisés comme sous-porteuses dans le temps, l'arrangement pilote de type bloc convient pour un canal sélectif en fréquence. Cependant, pour un canal à évanouissement rapide (fast fading channel), il pourrait en résulter en beaucoup de pertes en terme de débit utile afin de poursuivre les variations du canal en réduisant la période des symboles pilotes.[30]

3.1.2. Configuration en Peigne

La configuration de pilotes de type peigne est illustrée à la Figure 2.2. Dans ce type, chaque symbole OFDM contient des tonalités pilotes au niveau des sous-porteuses, qui sont utilisées pour une interpolation dans le domaine fréquentiel afin d'estimer le canal le long de l'axe des fréquences. Soit S_f la période des tonalités pilotes en fréquence. Afin de poursuivre les variations du canal sélective en fréquence, les symboles pilotes doivent avoir une fréquence identique à la

bande passante cohérente. Puisque la bande passante cohérente est déterminée par l'inverse de l'étalement maximal du retard, σ_{max} , la période du symbole pilote doit satisfaire l'inégalité suivante :

$$S_f \leq \frac{1}{\sigma_{max}} \quad (2.2)$$

Contrairement à l'arrangement de type bloc, l'arrangement de type peigne convient aux canaux à évanouissement rapide, mais pas aux canaux sélectifs en fréquence.[30]

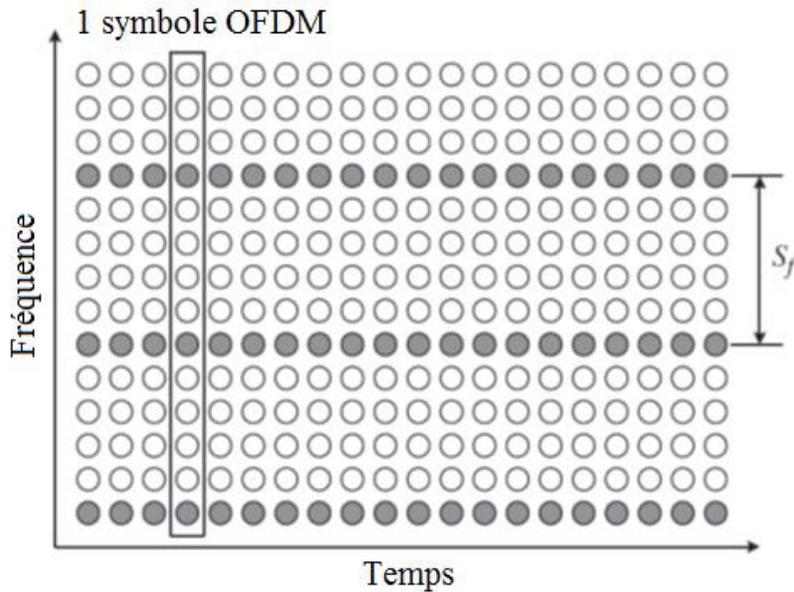


Figure 2.2 Disposition pilote de type peigne

3.1.3. Configuration en treillis

La configuration de type treillis est illustrée à la Figure 2.3. Dans ce type, des tonalités pilotes sont insérées le long des axes de temps et de fréquence avec des périodes données. Les tonalités pilotes dispersées dans les axes temporel et fréquentiel facilitent les interpolations dans le domaine temporel/fréquence pour l'estimation de canal. Soient S_t et S_f les périodes des symboles pilotes en temps et en fréquence, respectivement. Pour pouvoir poursuivre les variations en temps et la sélectivité en fréquence du canal, la disposition des symboles pilotes doit satisfaire à la fois les équations (2.1) et (2.2),

$$S_f \leq \frac{1}{f_{Doppler}} \text{ and } S_t \leq \frac{1}{\sigma_{Max}} \quad (2.3)$$

où $f_{Doppler}$ et σ_{max} désignent respectivement l'étalement de Doppler et l'étalement maximal de retard.[30]

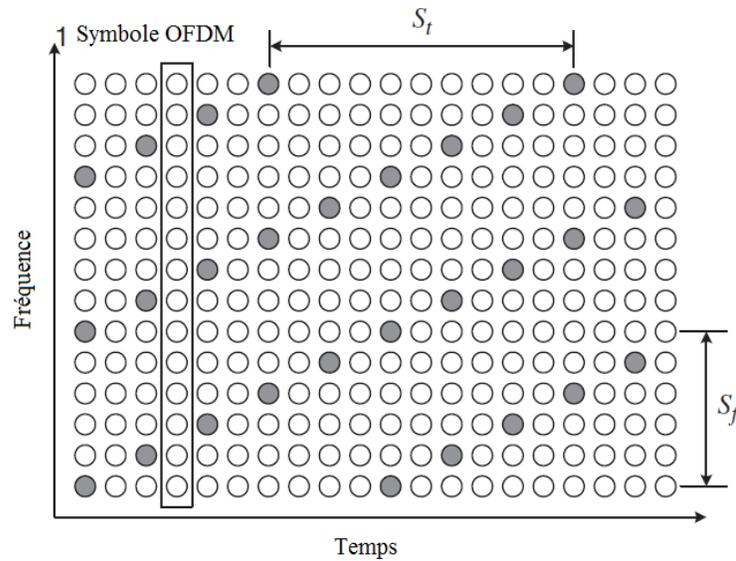


Figure 2.3 Disposition pilote de type treillis

4. L'erreur quadratique moyenne (MSE)

4.1. Définition de l'erreur quadratique moyenne

L'erreur quadratique moyenne (MSE) vous indique à quel point une droite de régression est proche d'un ensemble de points. Pour ce faire, il prend les distances entre les points et la droite de régression (ces distances sont les « erreurs ») et les met au carré. L'équerrage est nécessaire pour éliminer tout signe négatif. Cela donne également plus de poids aux différences plus importantes. C'est ce qu'on appelle l'erreur quadratique moyenne car on cherche toujours à trouver la moyenne d'un ensemble d'erreurs. Plus la MSE est faible, meilleures sont les prévisions.[8]

5. Bruit et interférences

5.1. Signal-to-Noise Ratio, SNR

Le rapport signal sur bruit est le rapport entre les puissances du signal utile et du bruit de fond indésirable.

$$SNR = \frac{P_{signal}}{P_{bruit}} \quad (2.4)$$

Généralement, le SNR est exprimé décibels en prenant le logarithme de la base 10 de la formule linéaire donnée ci-dessus [10] :

$$SNR(dB) = 10 \log_{10} \frac{P_{(signal)}}{P_{(bruit)}} \quad (2.5)$$

5.2. Bit Error Rate (BER) ou taux d'erreur binaire

Le BER désigne une valeur, relative au taux d'erreur, mesurée à la réception d'une transmission numérique, relative au niveau d'atténuation et/ou de perturbation du signal transmis.

Ce taux détermine le nombre d'erreurs apparues entre la modulation et juste après la démodulation du signal. Ce taux d'erreur ne tient généralement pas compte du codage des données sauf dans le cas d'une norme de transmission combinant modulation et correction d'erreur (par exemple, QPSK). La cause des perturbations, donc de l'augmentation du taux d'erreur, peut être multiple à savoir, équipement ou réseau défectueux, pointage incorrect d'une antenne, interférences, longueur des câbles, etc. Le BER s'exprime en puissance négative.

Par exemple, 10^{-3} signifie que l'on a en moyenne une erreur binaire pour mille bits transmis.

Le BER est calculé en comparant les séquences binaires, transmise et reçue, et en comptant le nombre d'erreurs. En réception, le rapport du nombre de bits erronés au nombre de bits total constitue le BER. Ce rapport mesuré est affecté par de nombreux facteurs, notamment le rapport signal sur bruit, la distorsion et le gigue.

Un taux d'erreur binaire de 10^{-9} est souvent considéré comme le BER minimum acceptable pour les applications de télécommunication. Les communications de données ont des exigences plus strictes où 10^{-13} est souvent considéré comme minimum.

Un BER trop élevé peut indiquer qu'un débit de données plus lent améliorerait en fait le temps de transmission global pour une quantité donnée de données transmises, car le BER pourrait être réduit, ce qui abaisserait le nombre de paquets qui devaient être renvoyés.

Le taux d'erreur binaire est défini comme le taux auquel les erreurs se produisent dans un système de transmission. Comme rappelé ci-dessus, le BER est le rapport du nombre de bits erronés au nombre total de bits transmis,[10]

$$\text{BER} = \frac{\text{Nombre de bits erronés}}{\text{Nombre de bits total transmis}} \quad (2.6)$$

6. Estimation de canal à base des symboles d'apprentissage

Les symboles d'apprentissage peuvent être utilisés pour l'estimation du canal, offrant généralement de bonnes performances. Cependant, l'efficacité de transmission est affectée en raison de l'insertion des symboles d'apprentissage (symboles pilotes), qui sont transmises en plus des symboles de données. Les techniques des moindres carrés (LS, pour Least Squares) et de l'erreur quadratique moyenne minimale (MMSE, pour Minimum Mean Square Error) sont largement utilisées pour l'estimation du canal lorsque des symboles d'apprentissage sont disponibles.

Supposons que toutes les sous-porteuses sont orthogonales, c.-à-d. la transmission est sans interférence entre porteuses (ICI, pour Inter-Carrier Interférence), les symboles d'apprentissage pour N sous-porteuses peuvent être représentés par la matrice diagonale suivante :

$$X = \begin{bmatrix} X[0] & 0 & \dots & 0 \\ 0 & X[1] & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & & 0 & [N-1] \end{bmatrix} \quad (2.7)$$

Où $X[k]$ désigne une tonalité pilote à la $k^{\text{ième}}$ sous-porteuse, avec $E\{X[k]\} = 0$ et $\text{Var}\{X[k]\} = \sigma_x^2$, $K = 0, 1, 2, \dots, N-1$. Notez que X est donné par une matrice diagonale, puisque nous supposons

que toutes les sous-porteuses sont orthogonales. Étant donné que le gain du canal pour chaque sous-porteuse k est $H[k]$, le signal d'apprentissage reçu, $Y[k]$, peut être donné par :

$$\begin{aligned}
 Y &\triangleq \begin{bmatrix} Y[0] \\ Y[1] \\ \vdots \\ Y[N-1] \end{bmatrix} = \begin{bmatrix} X[0] & 0 & \dots & 0 \\ 0 & X[1] & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & X[N-1] \end{bmatrix} \begin{bmatrix} H[0] \\ H[1] \\ \vdots \\ H[N-1] \end{bmatrix} + \begin{bmatrix} Z[0] \\ Z[1] \\ \vdots \\ Z[N-1] \end{bmatrix} \\
 &= XH + Z
 \end{aligned} \tag{2.8}$$

Où $H = [H[0], H[1], \dots, H[N-1]]^T$ est le vecteur du canal et $Z = [Z[0], Z[1], \dots, Z[N-1]]^T$ est le vecteur de bruit, avec $E\{Z[k]\} = 0$ et $Var\{Z[k]\} = \sigma^2$, $k = 0, 1, 2, \dots, N-1$. Notons que, dans la discussion suivante, \hat{H} représente l'estimé du canal H . [31]

7. Méthodes classiques pour l'estimation du canal

Parmi les méthodes d'estimation connues, celles basées sur le critère des moindres carrés (LS) et sur le critère de l'erreur quadratique moyenne minimum (MMSE) sont les plus étudiées et utilisées comme référence avec laquelle on compare les nouvelles méthodes proposées. Les développements suivants sont effectués avec une configuration des symboles pilotes dans le domaine fréquentiel. [30]

7.1. Méthode d'estimation LS (Least Squares)

La méthode des moindres carrés (LS) détermine l'estimé du canal, \hat{H} , de telle manière que la fonction de coût suivante soit minimisée :

$$\begin{aligned}
 J(\hat{H}) &= \|Y - X\hat{H}\|^2 \\
 &= (Y - X\hat{H})^H (Y - X\hat{H}) \\
 &= Y^H Y - Y^H X\hat{H} - \hat{H}^H X^H Y + \hat{H}^H X^H X\hat{H}
 \end{aligned} \tag{2.9}$$

Posons la dérivée par rapport à \hat{H} de la fonction coût à zéro,

$$\frac{\partial J(\hat{H})}{\partial \hat{H}} = -2(X^H Y)^* + 2(X^H X \hat{H}) = 0 \quad (2.10)$$

Nous avons $X^H X \hat{H} = X^H Y$, ce qui donne l'estimé au sens des moindres carrés suivant :

$$\hat{H}_{LS} = (X^H X)^{-1} X^H Y = X^{-1} Y \quad (2.11)$$

Notons la $k^{ième}$ composante de l'estimé du canal \hat{H}_{LS} par $\hat{H}_{LS}[k]$, $k = 0, 1, 2, \dots, N-1$. Puisque X est diagonal comme mentionné ci-dessus, l'estimé du canal au sens des moindres carrés \hat{H}_{LS} , peut être donné pour chaque sous-porteuse comme suit :

$$\hat{H}_{LS}[k] = \frac{Y[k]}{X[k]}, \quad k = 0, 1, 2, \dots, N-1 \quad (2.12)$$

L'erreur quadratique moyenne (MSE) de cette estimé du canal, \hat{H}_{LS} , est donnée par

$$\begin{aligned} MSE_{LS} &= E \left\{ (H - \hat{H}_{LS})^H (H - \hat{H}_{LS}) \right\} \\ &= E \left\{ (H - X^{-1} Y)^H (H - X^{-1} Y) \right\} \\ &= E \left\{ (X^{-1} Z)^H (X^{-1} Z) \right\} \\ &= E \left\{ Z^H (X X^H)^{-1} Z \right\} \\ &= \frac{\sigma_z^2}{\sigma_x^2} \end{aligned} \quad (2.13)$$

Notez que le MSE dans l'équation (2.13) est inversement proportionnel au rapport signal à bruit, $SNR = \sigma_z^2 / \sigma_x^2$, ce qui implique que le MSE peut être sujet à une augmentation du bruit, en particulier lorsque le canal est dans un zéro profond. Toutefois, la méthode LS a été largement utilisée pour l'estimation de canal en raison de sa simplicité. [31]

7.2. Méthode d'estimation LMMSE (Linear Minimum Mean Square Error)

Considérons la solution LS dans l'équation (2.11), $\hat{H}_{LS} = X^{-1} Y \triangleq \tilde{H}$. En utilisant la matrice de poids W, déterminons $\hat{H} \triangleq W \tilde{H}$, qui correspond à l'estimé du canal au sens MMSE.

En se référant à la Figure 2.4, la MSE de l'estimation de canal $\hat{H} \triangleq W\tilde{H}$ est donnée comme suit :

$$J(\hat{H}) = E\{\|e\|^2\} = E\{\|H - \hat{H}\|^2\} \quad (2.14)$$

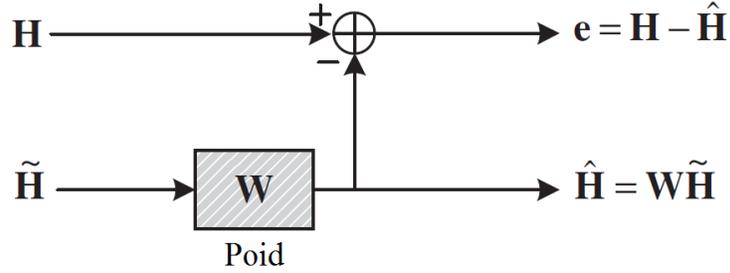


Figure 2.4. Schéma de l'estimation du canal au sens du critère MMSE

L'objectif, pour la méthode MMSE, est de trouver la meilleure estimation (linéaire) en termes de W de telle manière que la MSE dans l'équation (2.14) soit minimale. Le principe d'orthogonalité stipule que le vecteur d'erreur $e = H - \hat{H}$ est orthogonal à l'estimé \tilde{H} , tel que,

$$\begin{aligned} E\{e\tilde{H}^H\} &= E\{(H - \hat{H})\tilde{H}^H\} \\ &= E\{(H - W\tilde{H})\tilde{H}^H\} \\ &= E\{H\tilde{H}^H\} - WE\{\tilde{H}\tilde{H}^H\} \\ &= R_{H\tilde{H}} - WR_{\tilde{H}\tilde{H}} = 0 \end{aligned} \quad (2.15)$$

Où R_{AB} est la matrice de corrélation croisée de taille $N \times N$ des matrices A et B ($R_{AB} = E[AB^H]$)

, et \tilde{H} est l'estimé LS du canal donnée par l'équation suivante :

$$\tilde{H} = X^{-1}Y = H + X^{-1}Z \quad (2.16)$$

La résolution de l'équation (2.15) donne :

$$W = R_{H\tilde{H}}R_{\tilde{H}\tilde{H}}^{-1} \quad (2.17)$$

Où $R_{\tilde{H}\tilde{H}}$ est la matrice d'autocorrélation de \tilde{H} donnée par :

$$\begin{aligned}
R_{\tilde{H}\tilde{H}} &= E\{\tilde{H}\tilde{H}^H\} \\
&= E\{X^{-1}Y(X^{-1}Y)^H\} \\
&= E\{(H + X^{-1}Z)(H + X^{-1}Z)^H\} \\
&= E\{HH^H + X^{-1}ZH^H + HZ^H(X^{-1})^H + X^{-1}ZZ^H(X^{-1})^H\} \\
&= E\{HH^H\} + E\{X^{-1}ZZ^H(X^{-1})^H\} \\
&= E\{HH^H\} + \frac{\sigma_z^2}{\sigma_x^2} I
\end{aligned} \tag{2.18}$$

Et $R_{\tilde{H}\tilde{H}}$ est la matrice de corrélation croisée entre le vecteur de canal réel et le vecteur du canal estimé. En utilisant l'équation (2.18), l'estimé du canal au sens MMSE devient :

$$\begin{aligned}
\hat{H} &= W\tilde{H} = R_{\tilde{H}\tilde{H}}^{-1} R_{\tilde{H}\tilde{H}} \tilde{H} \\
&= R_{\tilde{H}\tilde{H}} \left(R_{HH} + \frac{\sigma_z^2}{\sigma_x^2} I \right)^{-1} \tilde{H}
\end{aligned} \tag{2.19}$$

Les éléments de la matrice $R_{\tilde{H}\tilde{H}}$ et de la matrice R_{HH} peuvent être donné par la formule suivante :

$$E\{h_{k,l}\tilde{h}_{k',l'}^*\} = E\{h_{k,l}h_{k',l'}^*\} = r_f[k-k']r_t[l-l'] \tag{2.20}$$

Où k et l désignent respectivement l'indice de sous-porteuse (domaine fréquentiel) et l'indice du symbole OFDM (domaine temporel). Notons que, la fonction d'autocorrélation est factorisée en deux fonctions séparées, en temps et en fréquence, $r_t[l]$ et $r_f[k]$, respectivement. Cette hypothèse est généralement justifiée dans des situations pratiques car le plus souvent l'étalement par trajets multiples ne dépend que de la description du diffuseur, alors que la variation Doppler de l'évanouissement dépend généralement du mouvement relatif entre l'émetteur et le récepteur ;

Dans un canal multi-trajets avec un PDP (Power Delay Profile) décrit par un exponentielle décroissant, la corrélation dans le domaine fréquentiel, $r_f[k]$, est donnée par :

$$r_f[k] = \frac{1}{1 + j2\pi\tau_{rms}k\Delta f} \tag{2.21}$$

Où $\Delta f = 1/T_{sub}$ est l'espace des sous-porteuses. Tandis que, pour un canal d'évanouissement avec une fréquence Doppler maximale f_{max} et un dont le spectre est donné par le modèle de Jake, la corrélation dans le domaine temporel $r_t[l]$ est donnée par [31]:

$$r_t[l] = J_0(2\pi f_{max} l T_{sym}) \quad (2.22)$$

Où $T_{sym} = T_{sub} + T_G$, où T_G est la durée de l'intervalle de garde et $J_0(x)$ est le premier terme de la fonction de Bessel d'ordre 0. Notez que, $r_t[0] = J_0(0) = 1$, ce qui implique que la corrélation dans le domaine temporel pour le même symbole OFDM est l'unité.

Notons que, jusqu'ici, l'estimation du canal est réalisée en utilisant les symboles pilotes dits aussi les symboles d'apprentissage. Pour étendre l'estimation aux symboles de données, les sous-porteuses pilotes doivent subir une interpolation. Parmi les méthodes d'interpolation les plus utilisées on trouve l'interpolation linéaire, l'interpolation polynomiale du second ordre et l'interpolation spline cubique. [31]

8. Techniques d'interpolation

La méthode d'estimation LS permet d'obtenir la réponse fréquentielle (bruitée) sur les porteuses pilote. Toutefois, il est nécessaire, dans la plupart des cas, d'effectuer une interpolation pour estimer le canal sur tout le réseau temps-fréquence. Notons d'abord que, l'estimateur LMMSE est un filtre de Wiener, donc un filtre interpolateur par nature. Pour plus de détail sur ce point, le lecteur est invité à se référer au chapitre 7 de la référence [32]. Cependant, la complexité de l'estimateur LMMSE fait qu'on préfère souvent utiliser des interpolations plus simples. Ces techniques d'interpolation sont basées tout simplement sur des polynômes interpolateurs, et n'ont besoin d'aucune caractéristique du canal ou du signal. Dans la suite, on va décrire quelques méthodes d'interpolations qui s'effectuent proprement sur l'axe fréquentiel.

8.1. Interpolation Nearest-Neighbor ou plus proche voisin

L'interpolation nearest-neighbor (NN) est la technique la plus simple car elle se base sur un polynôme intégrateur de degré zéro. Si on note f_p la position fréquentielle d'un pilote et δ_f l'écart

fréquentiel entre deux porteuses pilote consécutives, alors, $\forall f \in [f_p - \delta_f / 2, f_p + \delta_f / 2]$ on obtient :

$$\hat{H}(f) = \hat{H}(f_p) \quad (2.23)$$

Où $\hat{H}(f_p)$ est l'estimation LS du canal au niveau des pilotes. La **Figure 2.5 (a)** illustre le principe de l'interpolation NN autour d'une position pilote f_p . Notons que, malgré sa simplicité, il est évident que cette interpolation n'est adaptée que pour des canaux très peu sélectifs. [30]

8.2. Interpolation linéaire

L'interpolation linéaire est, elle aussi, relativement simple, car elle se base sur un polynôme interpolateur de degré 1. Pour une valeur $f \in [f_p, f_{p+\delta_f}]$, le canal estimé $\hat{H}(f)$ est la moyenne entre $\hat{H}(f_p)$ et $\hat{H}(f_p + \delta_f)$, pondérée par la distance $f_{p+\delta_f} - f_p$. Ainsi, on obtient :

$$\hat{H}(f) = \hat{H}(f_p) + (f - f_p) \frac{\hat{H}(f_{p+\delta_f}) - \hat{H}(f_p)}{f_{p+\delta_f} - f_p} \quad (2.24)$$

La **Figure 2.5 (b)** illustre le principe de l'interpolation linéaire entre deux positions fréquentielles de pilotes f_p et $f_{p+\delta_f}$. Bien qu'elle soit plus précise par rapport à l'interpolation NN, l'interpolation linéaire présente des résultats faibles lorsqu'il s'agit des canaux très sélectifs. [30]

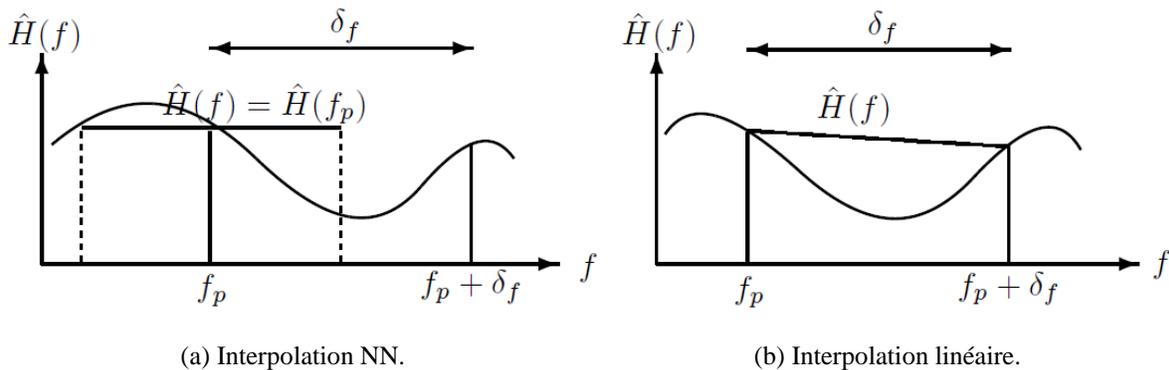


Figure 2.5 Illustration du principe des interpolations, Nearest-Neighbor et linéaire.

9. Autres méthodes d'estimation de canal

Il est impossible de faire une liste exhaustive de toutes les méthodes d'estimation du canal. Il existe une vingtaine de techniques usuelles. Parmi lesquelles, on peut citer les plus couramment utilisées :

- Le filtre de Wiener 2D : c'est l'estimateur optimal au sens de l'erreur quadratique moyenne. Il peut être vu comme une généralisation de la méthode LMMSE dans deux dimensions ; temps et fréquence. Cependant, sa complexité limite son utilisation.
- L'interpolation IFFT (pour interpolated Fast Fourier Transform) : Après avoir fait une estimation LS au niveau des pilotes, on repasse dans le domaine temporel au moyen d'une IFFT de taille P . L'interpolation est alors faite en rajoutant $M - P$ zéros au vecteur obtenu (zero padding), puis en appliquant une FFT de taille M .
- L'estimation du maximum de vraisemblance (ou ML, pour Maximum Likelihood), vise à maximiser la fonction de coût J_{ML} :

$$J_{ML} = \ln\left(p\left(U_n | H_n, \underline{C}_n, \sigma^2\right)\right) \quad (2.25)$$

Où $p\left(U_n | H_n, \underline{C}_n, \sigma^2\right)$ est la densité de probabilité conditionnelle du signal reçu. Classiquement, on considère un bruit blanc gaussien, alors la densité de probabilité conditionnelle est une loi normale à M variables, ce qui explique la présence du logarithme népérien dans (2.25) [30].

10. Conclusion

Un canal de transmission possède un caractère aléatoire. On peut trouver à la fois, la dispersion, la diffraction et réfraction, ce qui conduit aux phénomènes de propagation par trajets multiples et aussi l'effet masque. Cependant pour combattre les évanouissements, les solutions se trouvent dans les types de transmission et de l'estimation du canal qui ont pour fonction, élever de débit et aussi la fiabilité optimale de l'information transmise. La connaissance du type du canal ainsi que les perturbations dont ils font l'objet, permet de faire les choix pertinents qui s'imposent pour atteindre les résultats escomptés.

les principales méthodes d'estimation de canal dans un contexte OFDM est proposé. Deux estimateurs sont principalement détaillés : l'estimateur LS et l'estimateur LMMSE.

L'estimation de canal nécessite parfois une interpolation pour estimer les coefficients entre deux points connus appelés pilotes. Cependant, les interpolations créent des erreurs résiduelles ayant un impact sur la qualité de l'estimation.

Dans le prochain chapitre, nous allons présenter en détail les réseaux de neurones ainsi que l'apprentissage profond. Ces outils seront utilisés, dans le chapitre 4, pour réaliser un estimateur et détecteur en même temps.

Chapitre 3

Apprentissage Profond

1. Introduction

En premier lieu, il est nécessaire de définir clairement de quoi s'agit-il lorsqu'on parle lorsque de l'intelligence artificielle. Qu'est-ce que l'intelligence artificielle (AI, Artificial Intelligence), l'apprentissage automatique (ML, Machine Learning) et l'apprentissage profond (DL, Deep Learning).

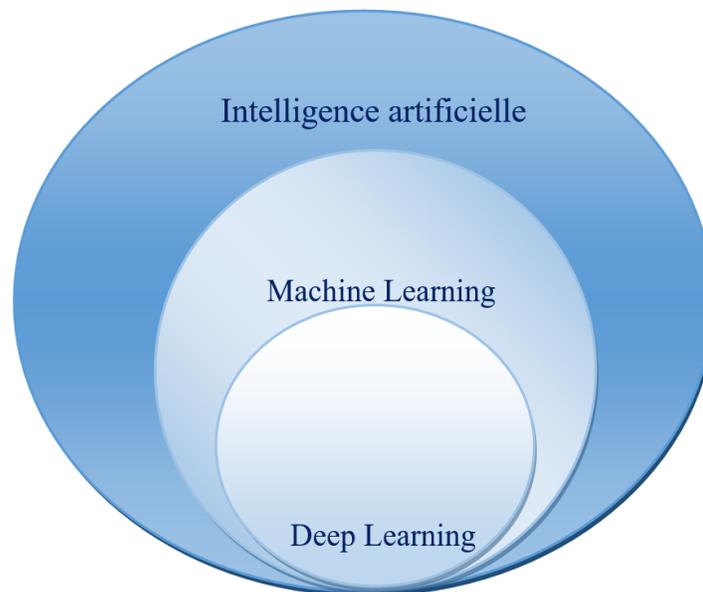


Figure 3.1. Intelligence artificielle, l'apprentissage automatique et l'apprentissage en profondeur

L'intelligence Artificielle est un domaine vaste, où nous essayons d'imiter le comportement humain dans le but de rendre les machines si puissantes pour accomplir de nombreux types de

tâches telles que la résolution de problèmes, la représentation des connaissances, la reconnaissance vocale, et autres. L'idée de base est de mettre les connaissances dans la machine. Grâce à ces deux domaines., il existe des systèmes sophistiqués capable de changer leur comportement sans qu'il soit nécessaire d'apporter des modifications à leurs structures, mais uniquement sur leurs données d'apprentissage. Ainsi, avec cette vague de techniques avancées d'apprentissage automatique qui donne à l'IA un pas en avant, où est la place de l'apprentissage profond ou qu'est-ce qu'il apporte dans ce domaine.

De nos jours, l'apprentissage profond est au centre de l'attention puisque sa réalisation est beaucoup plus importante que tout autre algorithme d'apprentissage automatique pour des tâches aussi complexes, parmi lesquelles on peut citer :

- Le traitement d'images et la reconnaissance de formes.
- La reconnaissance vocale et le traitement du signal.
- Les technologies de télécommunications.
- etc.

L'apprentissage profond est une classe des techniques de l'apprentissage automatique, où l'information est traitée en couches hiérarchiques pour comprendre les représentations et les caractéristiques de données dans des niveaux de complexité croissante. Toutefois, il faut savoir que tout est commencé avec l'apparition des réseaux de neurones et plus précisément du perceptron au début des années 40.

2. Historique

L'histoire de l'apprentissage profond est relativement récente, mais celle des réseaux de neurones remonte à 1943, lorsque Walter Pitts et Warren McCulloch avaient créé un modèle mathématique pour imiter le fonctionnement du neurone biologique. Depuis ce temps, les réseaux de neurones ont évolué régulièrement, avec seulement deux ruptures significatives dans leur développement [33]. En 1958, Frank Rosenblatt a créé le perceptron [34], un algorithme de reconnaissance de formes basé sur des opérations simples telles que l'addition et la multiplication. Au cours des années 70, l'intelligence artificielle a fait l'objet d'un bref recul. Le manque de financement a limité la recherche dans ce domaine. En 1979, le réseau de neurones artificiels multi-couches a vu le jour, il

s'appelé Neocognitron [36].

La rétro-propagation de l'erreur (error backpropagation) qui est un algorithme d'apprentissage de pour les réseaux de neurones, a considérablement évolué dans les années 70 et 80. C'est à ce moment que Rumelhart, Williams et Hinton [37] ont démontré que la rétro-propagation pouvait fournir des représentations de distribution intéressantes en améliorant considérablement les réseaux de neurones pour réaliser de nombreuses tâches telles que la reconnaissance de forme.

C'est également à cette époque que la deuxième rupture du développement de l'intelligence artificielle a eu lieu (1985-1990), ce qui a également permis d'effectuer des recherches sur les réseaux de neurones et l'apprentissage profond. La prochaine étape importante de l'évolution de l'apprentissage profond a eu lieu en 1999.

Vers l'année 2000, le problème du gradient est apparu. Il a été découvert que les caractéristiques formées dans les couches inférieures n'étaient pas apprises par les couches supérieures, car aucun signal d'apprentissage n'atteignait ces couches.

En 2011, la vitesse des GPU avait considérablement augmenté, ce qui permettait d'entraîner des réseaux de neurones convolutifs (CNN, Convolutional Neural Networks) sans l'apprentissage préalable couche par couche.

Depuis 2012, les algorithmes à base sur l'apprentissage profond semblent prêts à résoudre bien de problèmes : reconnaître des visages comme le propose DeepFace, vaincre des joueurs dans le Game Of Go (le Game Of Go est un jeu de stratégie, très répandu en extrême-orient, qui se joue à deux et qui consiste à former des territoires en posant des pions, ou pierres, sur un plateau. Le but est de marquer plus de points que l'adversaire en créant plus de territoires que lui et/ou en capturant ses pierres), ou de poker ou bientôt permettre la conduite de voitures autonomes ou encore la recherche de cellules cancéreuses.

L'article référence de Yann LeCun, Yoshua Bengio et Geoffrey Hinton, publié en 2015 dans la revue Nature [Deep Learning 2015], résume l'histoire depuis la naissance jusqu'aux derniers percées des réseaux de neurones et de l'apprentissage profond. En fait, ses auteurs se considèrent comme les pères de l'apprentissage profond.

3. Définition de l'apprentissage profond

L'apprentissage profond est un ensemble de méthodes d'apprentissage automatique ayant pour but la modélisation à haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires. Ces techniques ont permis des progrès importants et rapides dans les domaines de l'analyse du signal sonore ou visuel et notamment de la reconnaissance faciale, de la reconnaissance vocale, de la vision par ordinateur, du traitement automatisé du langage, etc. L'apprentissage profond est une technologie qui consiste à enseigner aux ordinateurs ce que les humains sont naturellement capables de savoir.

Bien que l'apprentissage profond est une branche particulière du l'apprentissage automatique, une autre différence majeure réside dans le fait que les performances des algorithmes de l'apprentissage profond évoluent avec l'évolution du volume de données, tandis que les algorithmes classiques de l'apprentissage automatique (shallow networks) convergent vers un état stable après un une certaine charge de données comme le montre la Figure 3.2. [38]

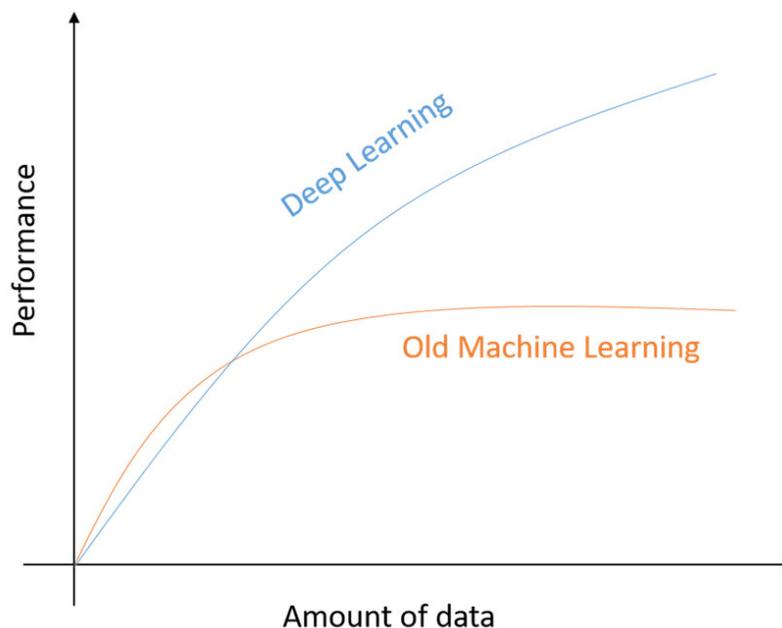


Figure 3.2. Intelligence artificielle, l'apprentissage automatique et l'apprentissage en profondeur

3.1. Intérêts de l'apprentissage profond

Les algorithmes classiques de l'apprentissage automatique fonctionnent très bien dans certains cas. Cependant, ils semblent être inefficaces avec les problèmes majeurs de l'apprentissage profond telles que la reconnaissance vocale et la reconnaissance d'objets. La principale différence entre l'apprentissage automatique traditionnel et l'apprentissage profond est l'étape de l'extraction de caractéristiques, ou en anglais, 'feature extraction', comme montré sur la Figure 3.3. Pour l'apprentissage automatique traditionnel les caractéristiques à identifier dépendent de l'expertise humaine. Cette pratique est très difficile et requiert un spécialiste en la matière, parfois les caractéristiques distinctives ne sont même pas identifiables par l'homme. L'apprentissage profond permet de pallier à ce problème en utilisant plusieurs couches de réseau de neurones. Les premières couches extrairont des caractéristiques simples (ex. présence de contours), alors que les couches suivantes combineront pour former des concepts de plus en plus complexes et abstraits : assemblages de contours en motifs, de motifs en parties d'objets, de parties d'objets en objets, etc. Un autre avantage de l'apprentissage profond c'est qu'il s'adapte bien au volume de données, plus le volume de données fournie est grand plus les performances sont meilleures. Les algorithmes de ML classiques quant à eux possèdent une borne supérieure à la quantité de données qu'ils peuvent recevoir appelée « plateau de performance », comme indiqué sur la Figure 3.2 [38] [39].

3.2. Domaines d'application de l'apprentissage profond

Ces techniques se développent dans le domaine de l'informatique appliquée aux NTIC (reconnaissance visuelle — par exemple d'un panneau de signalisation par un robot ou une voiture autonome — et vocale notamment) à la robotique, à la bio-informatique, la reconnaissance ou comparaison de formes, la sécurité, la santé, etc..., la pédagogie assistée par l'informatique, et plus généralement à toute sorte d'intelligence artificielle. L'apprentissage profond peut par exemple permettre à un ordinateur de mieux reconnaître des objets hautement déformables et/ou analyser par exemple les émotions révélées par un visage photographié ou filmé, ou analyser les mouvements et position des doigts d'une main, ce qui peut être utile pour traduire le langage des signes, améliorer le positionnement automatique d'une caméra, etc... Elles sont utilisées pour certaines formes d'aide au diagnostic médical (ex. reconnaissance automatique d'un cancer en imagerie médicale), de prospective ou de prédiction (ex. prédiction des propriétés d'un sol filmé par un robot) [40].

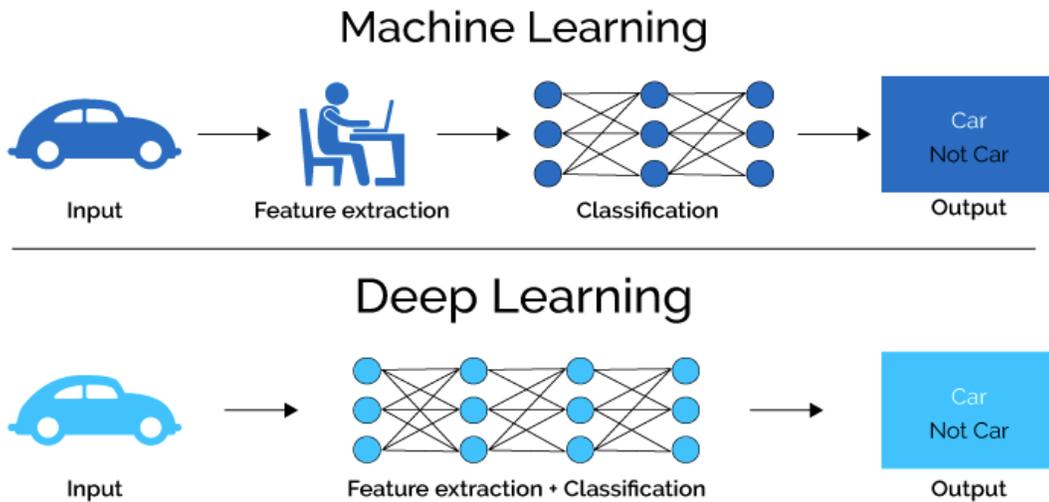


Figure 3.3. Apprentissage automatique vs. Apprentissage profond

3.3. Différentes structures d'apprentissage profond

Il existe 3 types de structures pour l'apprentissage profond qui sont :

- Les réseaux de neurones profonds (Deep Neural networks)
- Les réseaux de neurones convolutionnels (CNN, Convolutional Neural Networks)
- Réseaux de neurones récurrentes (RNN, Recurrent Neural Networks)
- Les auto-encodeurs (Auto-encoders)
- La machine de Boltzmann

3.4. Différent types d'apprentissage

La Figure 3.4 montre un schéma général des différentes catégories d'apprentissage automatique ainsi que les différents algorithmes et techniques appartenant à chaque catégorie d'apprentissage.

3.4.1. Apprentissage Supervisé

Pour ce type d'apprentissage, il existe toujours un ensemble d'apprentissage étiqueté, c.-à-d. un ensemble des entrées et en même temps les sorties désirées qui leur correspondent. Deux tâches principales sont réalisées par l'apprentissage supervisé, à savoir la régression et la classification.

On note que, dans ce mémoire on s'intéresse à l'apprentissage supervisé des réseaux de neurones profonds pour réaliser une tâche de régression, et ceci en utilisant le célèbre algorithme

d'apprentissage appelé Error Backpropagation [40].

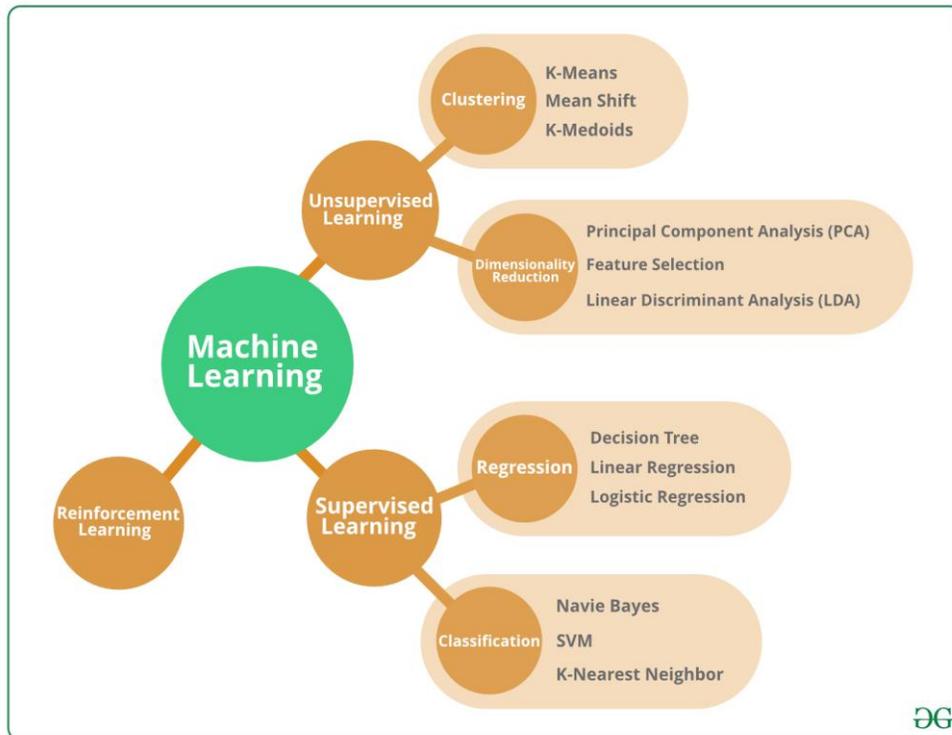


Figure 3.4. Différents types d'apprentissage

3.4.2. Apprentissage Non Supervisé

L'objectif de l'apprentissage non supervisé est de découvrir des modèles sous-jacents dans les données mais sans étiquette. A titre d'exemple, le regroupement des documents similaires à la base du contenu textuel.

3.4.3. Apprentissage par renforcement

Cette approche est basée sur le principe de retour/récompense. Un exemple pratique est le Game Of Go [41].

4. Perceptron multicouche (MLP pour Multi-Layer Perceptron)

Le perceptron Multicouche est un réseau orienté de neurones artificiels organisé en couches où l'information voyage dans un seul sens, de la couche d'entrée vers la couche de sortie comme indiqué sur la Figure 3.5. La couche d'entrée représente toujours une couche virtuelle associée aux

entrées du système. Elle ne contient aucun neurone. Les couches suivantes sont des couches de neurones, et les sorties des neurones de la dernière couche correspondent toujours aux sorties du système.

Dans le cas général, un Perceptron Multicouche peut posséder un nombre de couches quelconque et un nombre de neurones (ou d'entrées) par couche également quelconque. Les différents composants du perceptron multicouche sont résumés ci-après [42].

4.1. Neurones d'entrée

La première couche est appelée couche d'entrée. Elle recevra les données source que l'on veut utiliser pour l'analyse. Dans le cas de l'aide au diagnostic industriel, cette couche recevra les indicateurs de surveillance. Sa taille est donc directement déterminée par le nombre de variables d'entrées.

4.2. Neurones cachés

La seconde couche est une couche cachée, en ce sens qu'elle n'a qu'une utilité intrinsèque pour le réseau de neurones et n'a pas de contact direct avec l'extérieur. Les fonctions d'activation sont en général non linéaires sur cette couche mais il n'y a pas de règle à respecter. Le choix de sa taille n'est pas implicite et doit être ajustée. Souvent, il sera préférable pour obtenir de bons résultats, d'essayer le plus de tailles possibles.

4.3. Neurones de sortie

La troisième couche est appelée couche de sortie. Elle donne le résultat obtenu après compilation par le réseau de données d'entrée dans la première couche. Dans le cas de l'aide au diagnostic industriel, cette couche donne l'état de la machine. Sa taille est directement déterminée par le nombre de classes (ou modes de fonctionnement).

4.4. Fonctions d'activation

Une fonction d'activation est utilisée pour entrainer le réseau en transmettant des signaux aux autres nœuds entre les différentes couches. Les poids sont ensuite ajustés au fur et à mesure. Les fonctions sont nombreuses mais les plus utilisées sont :

- La fonction seuil
- La fonction sigmoïde
- La fonction tangente hyperbolique
- La fonction Relu (Unité de Rectification Linéaire)

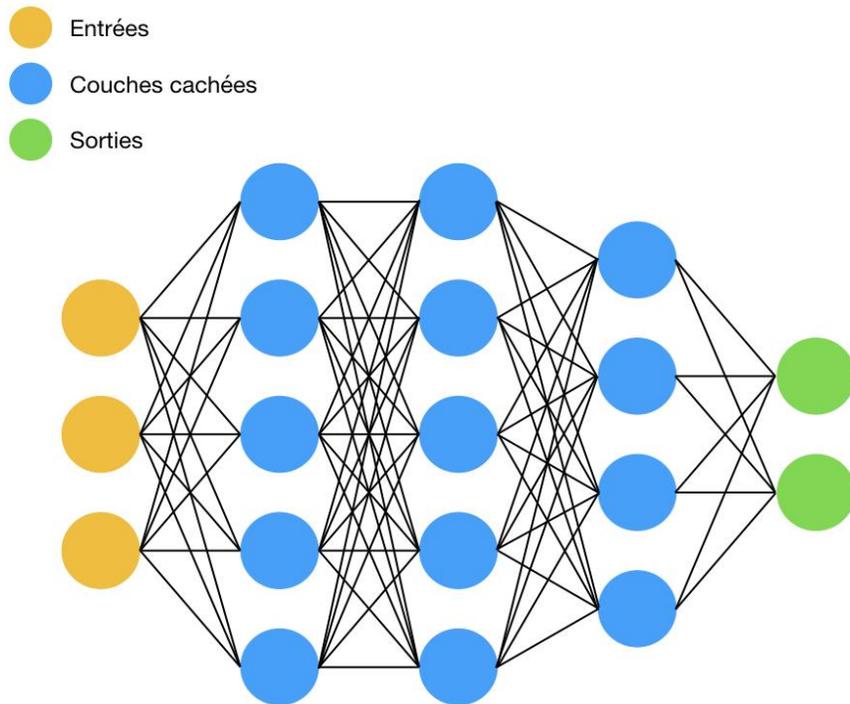


Figure 3.5. Perceptron Multicouche

La création d'un perceptron Multicouche pour résoudre un problème donné, passe donc par l'inférence de la meilleure application possible telle que définie par un ensemble de données d'apprentissage constituées de paires de vecteurs d'entrées et de sorties désirées. Cette inférence peut se faire, entre autres, par l'algorithme dit de retro-propagation de l'erreur (Error Backpropagation) [43].

5. Algorithme du Rétro-propagation de l'erreur

L'algorithme a été décrit en premier temps par Werbos [45] en 1974. Cependant, ce n'est qu'en 1986 lorsqu'il fut présenté par Rumelhart et McClelland [46] qu'il acquit une réelle acceptation dans la communauté scientifique. C'est un algorithme qui a été trouvé de façon indépendante par

plusieurs équipes de chercheurs (Rumelhart, Parker et LeCun).

Le but est de minimiser l'erreur quadratique moyenne entre les sorties obtenues et celle souhaitées qui correspond de nouveau à une descente du gradient mais alors que dans un réseau à une seule couche on était assuré de la convergence de la méthode, ce n'est plus le cas dans un réseau multicouche, et on pourrait éventuellement rester bloqué sur un minimum local et non global, il s'avère qu'en fait cela ne se produira pas dans la majorité des cas (mais cela reste expérimental).

Le principe est de redistribuer, sur toutes les couches y compris les couches cachées, une partie de l'erreur de manière récursive, en partant de la couche de sortie et en remontant vers la couche d'entrée d'où le préfixe 'rétro' [47].

5.1. Formalisme mathématique de l'algorithme BP

La rétro-propagation (RP) du gradient est une extension de la règle de Widrow appliquée aux réseaux monocouches. Son développement est lié aux travaux de Rumelhart et al [48]. La rétro-propagation consiste à minimiser la distance entre la sortie calculée $Z(q)$ et la sortie désirée $T(q)$ correspondante à chaque exemple d'apprentissage $X(q)$. L'erreur quadratique est souvent employée comme étant la fonction coût de cet algorithme :

$$E = \frac{1}{2} \sum_{q=1}^Q \sum_{j=1}^J \left(t_j^{(q)} - z_j^{(q)} \right)^2 \quad (3.1)$$

Considérons la notation montrée sur le réseau à deux couches cachées de la Figure 3.6.

L'algorithme de la RP modifie les poids du réseau de façon à minimiser l'erreur. Au début de l'apprentissage, les poids sont initialisés aléatoirement et modifiés ensuite dans une direction qui réduira l'erreur. La modification d'un poids w est donnée par :

$$\Delta w = -\eta \frac{\partial E}{\partial w} \quad (3.2)$$

Où : η est une constante positive (entre 0 et 1) appelée pas d'apprentissage [49].

Chaque poids est modifié à l'itération $(r + 1)$ en fonction de sa valeur à l'itération (r) par :

$$w^{(r+1)} = w^{(r)} + \Delta w^{(r)} \quad (3.3)$$

Pour un MLP avec une couche cachée, la mise à jour des poids de la couche cachée et ceux de la couche de sortie est donnée par :

$$u_{mj}^{(r+1)} = u_{mj}^{(r)} - \eta \frac{\partial E^{(r)}}{\partial u_{mj}} \quad (3.4)$$

$$w_{nm}^{(r+1)} = w_{nm}^{(r)} - \eta \frac{\partial E^{(r)}}{\partial w_{nm}} \quad (3.5)$$

$$v_{kn}^{(r+1)} = v_{kn}^{(r)} - \eta \frac{\partial E^{(r)}}{\partial v_{kn}} \quad (3.6)$$

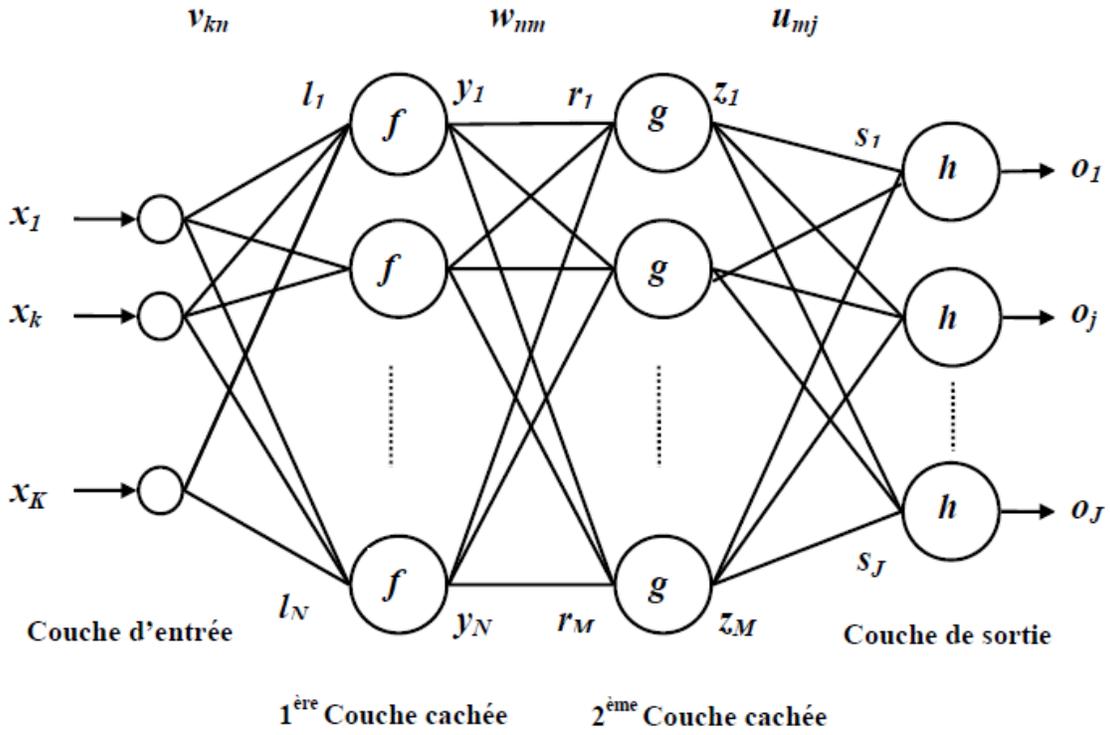


Figure 3.6. Perceptron multicouche

Le développement des équations (3.4), (3.5), et (3.6) donne les équations suivantes :

$$u_{mj}^{(r+1)} = u_{mj}^{(r)} + \eta_1 (t_j - o_j) h'(s_j) z_m \quad (3.7)$$

$$w_{nm}^{(r+1)} = w_{nm}^{(r)} + \eta_2 \left(\sum_{j=1}^J (t_j - o_j) h'(s_j) u_{mj} \right) g'(r_m) y_n \quad (3.8)$$

$$v_{kn}^{(r+1)} = v_{kn}^{(r)} + \eta_3 \left(\sum_{j=1}^J \sum_{m=1}^M (t_j - o_j) h'(s_j) u_{mj} g'(r_m) w_{nm} \right) f'(l_n) x_k \quad (3.9)$$

Où : η_1 , η_2 , et η_3 , sont les pas d'apprentissage, et f , g , et h , sont respectivement les fonctions d'activation des neurones de la première et la deuxième couche cachée, et de la couche de sortie. Dans le cas des fonctions sigmoïdes, les dérivées sont données par :

$$g'(s) = o(1-o) \quad (3.10)$$

$$g'(s) = (1+o)(1-o) \quad (3.11)$$

6. Réseaux de neurones profonds

Il est possible d'apprendre des modèles tels que les réseaux de neurones, à accomplir certaines tâches. Cependant les réseaux de neurones ont très longtemps été limités dans leurs architectures, en particulier concernant leur profondeur, c'est-à-dire, le nombre de couches qu'ils pouvaient apprendre. Cette limitation s'est effondrée dans les années 2010-2012 avec l'arrivée de bases de données bien plus grandes accompagnées de capacités de calcul et de stockage plus importantes. Cette avancée a également été permises par des architectures de réseaux de neurones différentes, plus faciles à apprendre et mieux adaptées à certains types de données [50].

Les DNNs (Deep Neural Network) effectuent la propagation vers l'avant de l'information (Feed-forward). Ils comprennent une couche d'entrée, plusieurs couches cachées et une couche de sortie comme montré sur la Figure 3.7. Les couches cachées et la couche de sortie se composent de nœuds où la sortie d'une couche est une entrée de la couche suivante. Ces nœuds effectuent deux sommes des leurs entrées puis passent le résultat à une fonction d'activation le plus souvent non linéaire, sauf dans le cas de la couche de sortie où la fonction d'activation est linéaire[51].

L'apprentissage des DNNs par la rétropropagation du gradient (le gradient de l'erreur pour chaque neurone est calculé de la dernière couche vers la première) entraînant des problèmes fondamentaux. Autrement dit, une fois que les erreurs sont rétro-propagées aux premières couches, elles deviennent minuscules et l'apprentissage devient inefficace. Afin de surmonter ce problème d'autres techniques d'apprentissage sont introduites [52, 53]

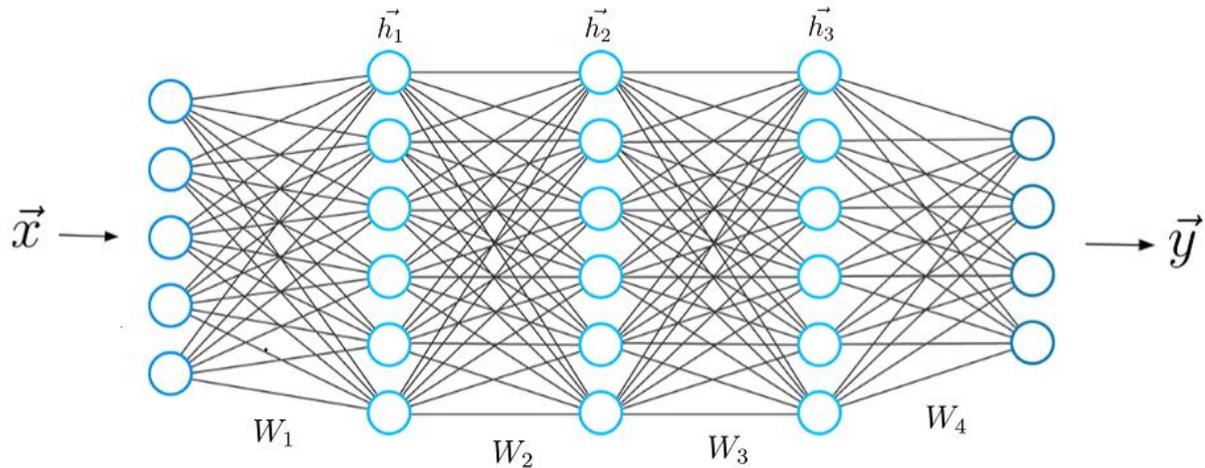


Figure 3.7. Architecture du DNN (Le réseau pour contenir plus de couches cachées)

6.1. Avantages des réseaux profonds

Les réseaux profonds représentent des avantages tels que :

- Les réseaux profonds sont capables d'apprendre des fonctions complexes. [54]
- Ils possèdent de bonnes capacités de généralisation. [55]

6.2. Inconvénients des réseaux profonds

Les réseaux profonds ont aussi des inconvénients tels que :

- Les réseaux profonds nécessitent une grande quantité de données. [54]
- Ils sont extrêmement coûteux en apprentissage. [55]

7. Langage de Programmation Python version 3.7.4

Python est un langage de programmation interprété (Date de première version 20 février 1991), multiparadigme et multiplateformes. Il favorise la programmation impérative structurée, fonctionnelle et orientée objet. Il est doté d'un typage dynamique fort, d'une gestion automatique de la mémoire par ramasse-miettes et d'un système de gestion d'exceptions ; il est ainsi similaire à Perl, Ruby, Scheme, Smalltalk et Tcl.

Le langage Python est placé sous une licence libre proche de la licence BSD4 et fonctionne sur la plupart des plates-formes informatiques, des smartphones aux ordinateurs centraux⁵, de Windows à

Unix avec notamment GNU/Linux en passant par macOS, ou encore Android, iOS, et peut aussi être traduit en Java ou .NET. Il est conçu pour optimiser la productivité des programmeurs en offrant des outils de haut niveau et une syntaxe simple à utiliser.

Il est également apprécié par certains pédagogues qui y trouvent un langage où la syntaxe, clairement séparée des mécanismes de bas niveau, permet une initiation aisée aux concepts de base de la programmation.

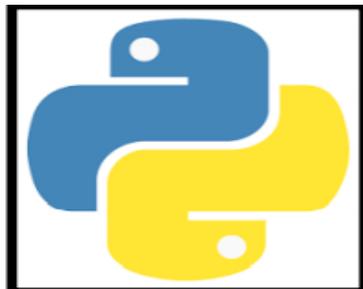


Figure.3.8. Logo Python v3.7.

7.1. Utilisation

Python est un langage qui peut s'utiliser dans de nombreux contextes et s'adapter à tout type d'utilisation grâce à des bibliothèques spécialisées. On l'utilise également comme langage de développement de prototype lorsqu'on a besoin d'une application fonctionnelle avant de l'optimiser avec un langage de plus bas niveau. Il est particulièrement répandu dans le monde scientifique, et possède de nombreuses bibliothèques optimisées destinées au calcul numérique

7.2. JetBrains PyCharm Community Edition 2018.3.4

PyCharm est un environnement de programmation léger et open source dédiée au développement de programmes en Python uniquement. Ergonomique, l'interface de PyCharm est divisée en deux blocs et vous permet d'avoir une vue d'ensemble des projets par arborescence dans la fenêtre de gauche, ainsi que de travailler via un éditeur de code dans l'encart de droite. Par ailleurs, notez que l'éditeur a été pensé dans le but de faciliter la programmation et fait état de fonctionnalités intelligentes telles que la vérification de bugs à la volée, la correction rapide des erreurs, ou encore le nettoyage de votre code. [43]



Figure.3.9. Logo PyCharm v2018.3.4.

7.3. Plateforme du deep learning TensorFlow

En savoir plus sur la bibliothèque open source développée par Google pour l'apprentissage par la machine et la recherche sur les réseaux de neurones profonds. A. TensorFlow TensorFlow est une bibliothèque de logiciels open source pour le calcul numérique à l'aide de graphiques de flux de données. Il a été développé à l'origine par Google Brain Team au sein de l'organisation de recherche Machine Intelligence de Google pour l'apprentissage par la machine et la recherche sur les réseaux neuronaux profonds, mais le système est suffisamment général pour pouvoir s'appliquer à une grande variété d'autres domaines également. Il a atteint la version 1.0 en février 2017 et a poursuivi son développement rapide, avec plus de 21 000 engagements jusqu'à présent, dont de nombreux contributeurs extérieurs. [38]

Cet article présente TensorFlow, sa communauté open source et son écosystème, et présente quelques modèles intéressants à source ouverte TensorFlow. TensorFlow est Multi-Plateforme. Il fonctionne sur presque tous les processeurs graphiques et les processeurs, y compris les plateformes mobiles et intégrées, et même les unités de traitement de tenseurs (TPU), qui sont du matériel spécialisé permettant d'effectuer des calculs de tenseurs. Ils ne sont pas encore largement disponibles, mais nous avons récemment lancé un programme alpha. [44]



Figure.3.10. Logo de TensorFlow.

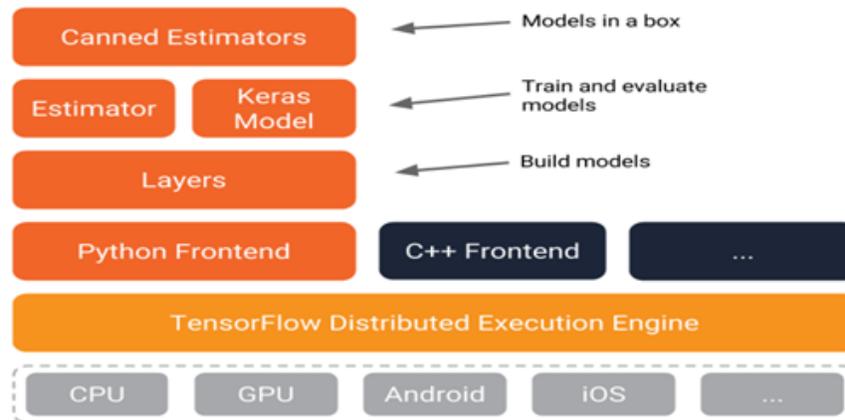


Figure.3.11. Hiérarchie de TensorFlow.

Le moteur d'exécution distribué TensorFlow extrait les nombreux périphériques pris en charge et fournit un cœur hautes performances implémenté en C++ pour la plate-forme TensorFlow, En plus de cela, vous trouverez les interfaces Python et C++ (avec d'autres à venir). L'API de couches fournit une interface plus simple pour les couches couramment utilisées dans les modèles d'apprentissage profondi. [43]

De plus, des API de niveau supérieur, notamment Keras (plus d'informations sur le site Keras.io) et l'API Estimator, facilitent la formation et l'évaluation des modèles distribués[54].

8. Conclusion

Dans ce chapitre nous avons montré un aperçu sur l'apprentissage profond On peut dire que cette technologie a été en avance sur son temps. Les applications d'apprentissage profond sont nombreuses et touche tous les domaines, celui-ci est particulièrement riche et le nombre

d'applications augmente constamment depuis quelques années. Les réseaux de neurones peuvent apprendre de manière supervisée ou non-supervisée. Les différents algorithmes utilisés dans le MLP ont vu le jour durant le XXe siècle. Durant des années, l'apprentissage se fait par l'algorithme de la rétropropagation du gradient (ou une variante de cette méthode) sur une base de données le plus large possible. Nous terminons avec une explication simple sur les deux programme Python et PyCharm.

Chapitre 4

Simulation et résultats

1. Introduction

Historiquement, l'estimation de canal OFDM a été étudiée minutieusement. Les méthodes classiques d'estimation LS et MMSE ont été utilisées et optimisées dans des différentes conditions. La méthode d'estimation LS ne nécessite aucune statistique de canal et ses performances être insuffisantes, par contre la méthode MMSE donne des meilleures performances d'estimation grâce à l'utilisation des statistiques du deuxième ordre du canal.

Dans ce chapitre on va présenter et analyser les résultats obtenus d'estimation du canal et de détection dans un système OFDM à l'aide de méthodes d'estimation classiques et celles basées sur les techniques d'apprentissage profond. Nous avons utilisé le langage MATLAB avec les algorithmes classiques et le langage Python pour les techniques de l'apprentissage profond.

L'évaluation des performances de différentes méthodes est portée sur la comparaison des courbes MSE de différents estimateurs.

2. Architecture du système

Le système de communication OFDM est composé de trois grandes parties à savoir, la partie émission, la partie canal de transmission et finalement, la partie réception où se trouve l'estimateur du canal suivi d'un égaliseur pour restaurer le signal original.

L'architecture du système OFDM avec estimation du canal et détection de symboles, basée sur l'apprentissage profond est illustrée sur la Figure 4.1. Notons que, les deux fonctions, estimation et détection ensemble sont réalisées par un seul réseau profond. Cette architecture est la même que celle utilisée avec les estimateurs classiques, sauf que ces derniers réalisent uniquement l'estimation mais pas la détection.

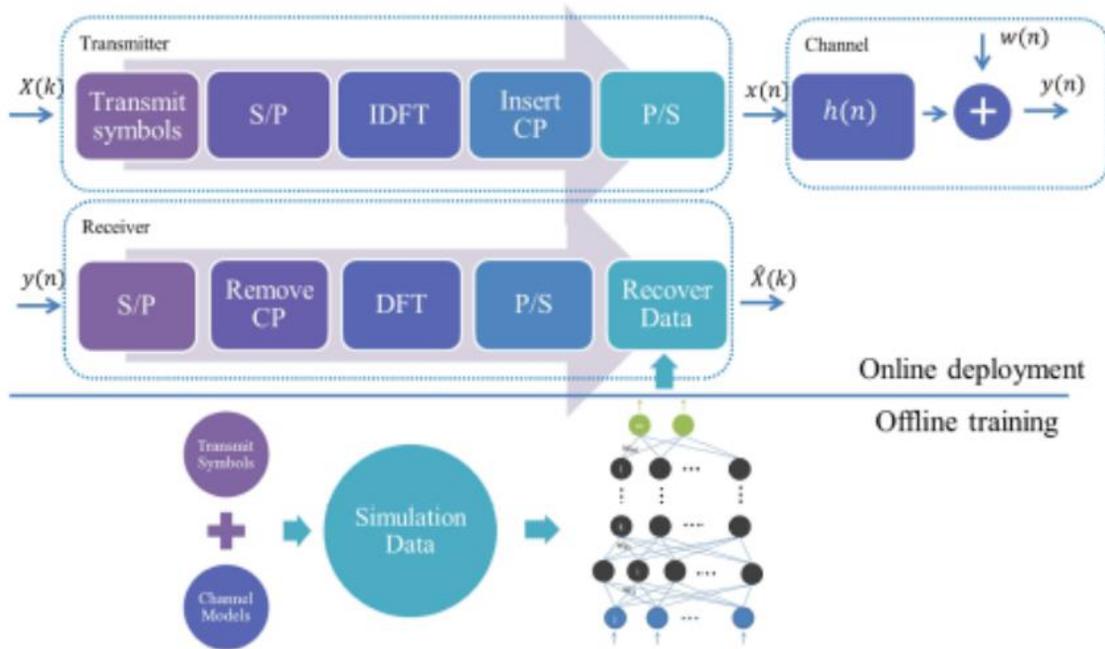


Figure 4.1. Schéma du système OFDM en présence d'un estimateur/détecteur DNN.

Comme le montre la figure ci-dessus, les symboles transmis, ainsi que les pilotes, sont convertis en un flux de données en parallèle, puis la transformée de Fourier discrète inverse (IDFT) est utilisée pour convertir le signal du domaine fréquentiel au domaine temporel. Ensuite, un préfixe cyclique (CP) est inséré pour atténuer l'interférence entre les symboles OFDM. Notons que, la longueur du CP ne doit pas être inférieure à longueur du canal.

Etant donné un canal multi-trajets décrit par des variables aléatoires complexes $\{h(n)\}$. Le signal reçu peut être exprimé comme suit :

$$y(n) = x(n) * h(n) + w(n) \quad (4.1)$$

Où $*$ désigne la convolution circulaire tandis que $x(n)$ et $w(n)$ représentent le signal transmis et le bruit blanc gaussien additif, respectivement. Après avoir supprimé le CP et effectué la DFT, le signal reçu dans le domaine fréquentiel est :

$$Y(k) = X(k)H(k) + W(k) \quad (4.2)$$

Où $Y(k)$, $X(k)$, $H(k)$ et $W(k)$ sont les DFT de $y(n)$, $x(n)$, $h(n)$ et $w(n)$, respectivement.

L'entrée du réseau DNN est composée de deux symboles OFDM, l'un pour les symboles pilotes et l'autre pour les symboles donnés. Supposons que, le canal est constant sur une durée de deux symboles OFDM, il varie donc d'un échantillon à un autre de l'entrée du DNN.

Notons également que, la mise en œuvre du réseau DNN est réalisée en deux étapes. La première étape consiste à faire un apprentissage du réseau en offline, c.-à-d. un apprentissage avec un ensemble de données qui tente de prendre en considération la maximum d'informations statistiques sur différents types de canaux, urbain, rurale, etc. La deuxième étape, ou déploiement online, consiste à mettre le réseau DNN en service pour estimer le canal et détecter les symboles sans aucun apprentissage.

Le réseau utilisé est composé de cinq couches, une couche d'entrée, trois couches cachées et une couche de sortie. Le nombre de neurones dans chaque couche est 256, 500, 250, 120 et 16, respectivement. Comme indiqué ci-dessus, nous avons utilisé deux symboles OFDM en entrée, donc une concaténation de deux vecteurs complexes, chacun de longueur 64 (sous-porteuse), ce qui conduit à un vecteur de longueur 128 éléments complexes. La concaténation de la partie réelle et la partie imaginaire de ce vecteur conduit à un vecteur réel de longueur 256 (car, tout simplement, tensorflow supporte généralement les opérations sur les nombres réels).

Concernant la sortie du réseau DNN, rappelons que le réseau reçoit deux symboles OFDM à son entrée, dont le deuxième est un vecteur complexe, de taille $[64 \times 1]$, est purement donnée, équivalent donc à 128 bits d'information.

Par conséquent, le choix le plus direct est d'imaginer que la sortie du réseau est un vecteur réel de taille $[128 \times 1]$, où chaque élément du vecteur de sortie correspond à un bit récupéré. Cependant, l'approche directe n'a pas été choisi mais une autre approche consistant à utiliser 8 réseaux parallèles, dont chacun a exactement la même entrée et la même structure, et est responsable de la

détection de 16 bits uniquement. Le premier réseau détecte le premier groupe des bits allant de 1^{er} au 16^{ème} bit, le second réseau détecte le second groupe allant de 17^{ème} au 32^{ème} bit et ainsi de suite, conduisant ainsi à la détection du symbole complet, 128 bits.

Notons ici les deux points principaux suivants. Premièrement, bien que chaque réseau ne détecte que 16 bits, les deux symboles OFDM sont lui fournis. En effet, chaque bit dans le système OFDM est lié à tous les bits des symboles reçus (rappelons la présence de l'IFFT qui est une somme de tous les symboles). Il est donc plus utile de donner toutes les informations disponibles au réseau pour lui renforcer la capacité du traitement. Deuxièmement, il est possible de détecter directement 128 bits avec un seul réseau, mais selon les auteurs de la référence [57], les performances (basées sur le taux d'erreur binaire) sont faibles que lorsqu'on adopte la stratégie de division en huit réseaux. Par conséquent, bien que la division en 8 réseaux augmente la complexité, les performances sont beaucoup améliorées.

D'autre part, un seul réseau doit être simulé au lieu de 8 réseaux. La justification de cette technique est le choix du taux d'erreur binaire comme fonction de performance. En fait, le taux d'erreur binaire n'est autre que la moyenne des bits, donc l'erreur d'un seul réseau de 16 sortie peut être considérée comme la moyenne de l'erreur sur 8 réseaux, donc le résultat de la simulation d'un réseau sera le même que celui de 8 réseaux.

Les couches cachées contiennent 500, 250 et 120 neurones, respectivement. Dans ce cas, on ne peut pas considérer vraiment ce réseau comme étant profond, toutefois le nombre de neurones cachés est relativement considérable pour lui appeler ainsi.

3. DNN vs. Estimateurs classiques

Dans cette partie on va faire une comparaison entre les différentes courbes BER obtenus de simulation des différentes méthodes d'estimation de canal (LS-Spline, LS-Linéaire, DNN et MMSE)

La modulation utilisée pour moduler la séquence binaire initiale est la modulation de phase à quatre états, QPSK. Le nombre de sous-porteuses utilisées par le système OFDM est 64. La longueur du préfixe cyclique (ou intervalle de garde) est de l'ordre de 16. Ce nombre est choisi de telle sorte qu'il soit identique avec la longueur du canal, qui est un canal de WINNER II de longueur de 16. Nous avons utilisé une séquence contenant un million de vecteur, chacun de longueur 16

représentant ainsi les variations en temps des coefficients du canal. Rappelons que, ces coefficients sont la principale variable à estimer constituant ainsi l'objet de ce mémoire. Pour plus de détail sur le canal de WINNER II, le lecteur est invité à se référer à la référence [56].

Le niveau du SNR considéré durant cette simulation est 25 dB. Le changement de cette valeur n'a aucun effet sur l'opération d'apprentissage [57].

L'outil de mesure de performances de différents estimateurs est le BER. Le MSE peut aussi constituer un outil de mesure convenable.

3.1. Résultats

Après avoir présenté les différentes conditions sous lesquelles l'expérience de simulation est réalisée, on peut maintenant passer directement aux résultats de simulation et à la comparaison de différentes courbes BER, permettant ainsi une bonne analyse du comportement de chacun des estimateurs. La courbe suivante donne les courbes BER de quatre estimateurs à savoir, l'estimateur LS avec interpolation linéaire, l'estimateur avec interpolation spline, l'estimateur MMSE et l'estimateur à base de DNN.

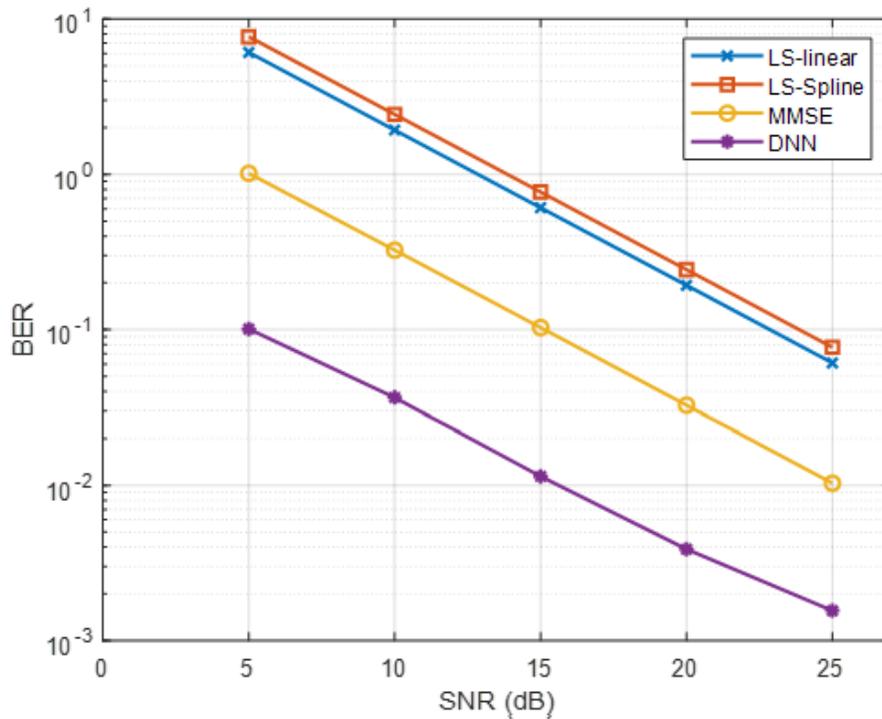


Figure 4.2. Courbes BER des différents estimateurs.

3.2. Analyses et commentaires

La Figure 4.2 montre les courbes BER des différents estimateurs. Il est bien clair que L'estimateur à base de l'apprentissage profond présente les meilleurs résultats avec un écart remarquable par rapport aux deux autres estimateurs. L'estimateur MMSE vient en deuxième rang en termes de performances, tandis que l'estimateur LS a montré les plus faibles résultats. Toutefois, il est à noter que l'algorithme d'interpolation linéaire est légèrement supérieur à l'algorithme spline en termes de performances BER, et encore avec un gain en termes de complexité, puisque l'algorithme d'interpolation est moins complexe et plus simple relativement à l'algorithme spline.

Ces résultats montrent que les réseaux de neurones profonds sont plus capables d'apprendre les variations intrinsèques du canal au cours du temps que les estimateurs classiques. Ces résultats vont certainement être au profit des réseaux profonds même avec une sévérité accrue du canal où les estimateurs classiques peuvent échouer à la caractérisation précise du canal comparativement aux estimateurs à base de l'apprentissage profond.

4. L'effet du nombre des pilotes sur les performances de DNN

Dans cette partie on va faire une comparaison entre les courbes obtenus par simulation de l'estimateur à base de DNN avec 2 valeurs différentes de nombre des pilotes utilisés.

La première valeur expérimentée va être 8 symboles pilotes, tandis que la deuxième va prendre 64 symboles pilotes.

En gardant les mêmes paramètres utilisés dans la comparaison précédente (Type de modulation, nombre de sous-porteuses utilisés dans le système OFDM, longueur de l'intervalle de garde, type et longueur de canal, nombre de vecteur dans chaque séquence et leurs longueur, l'outil d'évaluation des performances. etc.).

4.1. Résultats

Après la présentation des conditions de simulation de l'expérience, on présente maintenant les résultats de simulation résumé en deux courbes qui montrent la variation du BER dans les deux cas d'arrangement, 8 pilotes, puis 64 pilotes. Les courbes BER sont illustrées sur la Figure 4.3.

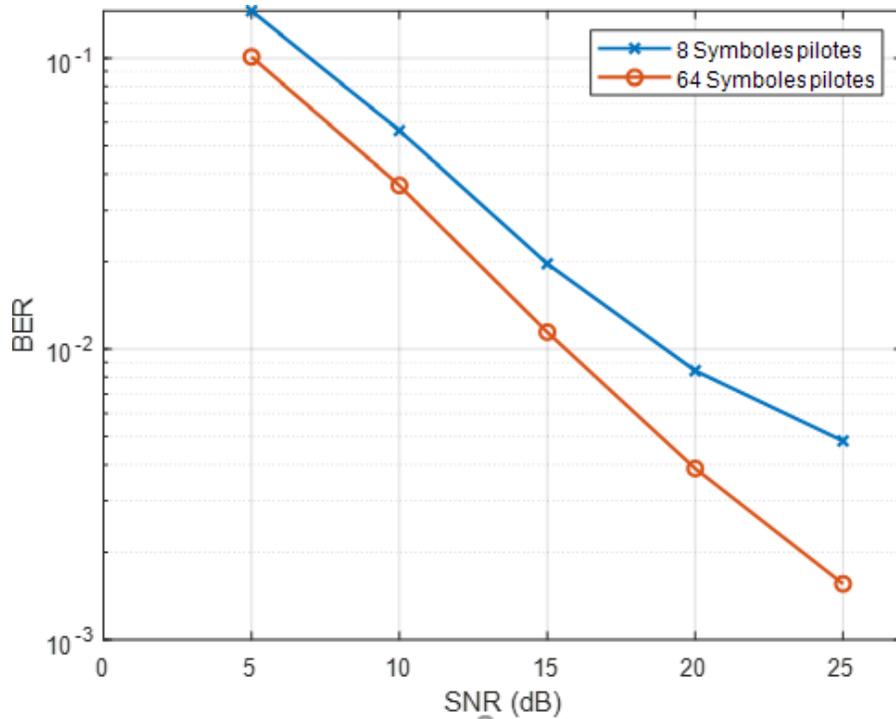


Figure 4.3. Courbes BER d'estimateur DL avec 2 différents nombres des pilotes.

4.2. Analyses et commentaires

La Figure 4.3 montre les courbes BER obtenu en simulant l'estimateur à base de DNN en prenant deux nombres différents des pilotes pour chaque simulation.

On remarque que l'estimateur à 64 symboles pilotes est plus performant que l'estimateur à 8 symboles pilotes avec un taux d'erreur binaire plus faible pour toutes les valeurs du SNR.

Ces résultats montrent que les réseaux de neurones profonds nécessitent un grand nombre des symboles pilotes pour avoir des meilleures performances, minimiser le taux d'erreur binaire (BER), et d'apprendre les variations en temps du canal. Toutefois, on peut remarquer facilement que, les performances du réseau DNN à 8 symboles pilotes sont supérieures à celles de l'estimateur MMSE, et ceci en comparant les deux figures 4.2 et 4.3. Ainsi, on peut dire que, même avec un nombre faible de symboles pilotes, l'estimateur DNN est plus performant que les estimateurs classiques.

5. Conclusion

Dans ce chapitre, nous avons montré une comparaison entre les estimateurs classiques, LS et MMSE et l'estimateur à base de l'apprentissage profond ou DNN. Les résultats semblent clairement au profit de l'estimateur à base du réseau DNN. La comparaison des performances est portée sur les courbes BER entre le canal réel et le canal estimé, pour les différents estimateurs utilisés.

Il a été montré sur plusieurs nouveaux articles qu'il est possible d'utiliser d'autres techniques d'apprentissage profond comme les réseaux de neurones convolutionnels, CNN, ou les réseaux de neurones récurrents, RNN, pour l'estimation du canal.

Il est également plus utile de passer aux systèmes de communications MIMO-OFDM où le canal est représenté par une matrice au lieu d'un vecteur. Bien évidemment, les techniques d'estimation se conservent mais les performances ne sont plus garanties vu la complexité du canal dorénavant. Toutefois, les techniques d'apprentissage profond sont bien connues par une meilleure poursuite des variations même en termes de complexité.

Conclusion Générale

Ce mémoire est consacré à l'estimation des canaux de transmission OFDM, en utilisant des structures à base des réseaux de neurones artificielles et pour minimiser les inconvénients des estimateurs classiques (Méthode d'estimation Least square (Ls) et Linear Minimum mean square error (LMMSE)).

Notre choix des réseaux de neurones tel que un outils pour l'estimation est motivé par les travaux de **Hao Ye et al.** Sur les applications des réseaux de neurones profonds (apprentissage profond) pour réaliser la fonction d'estimation dans les systèmes de communications sans fil. Ce mémoire est donc une sorte de reproduction de leur papier intitulée : « Power of Deep Learning for Channel Estimation and Signal Détection in OFDM Systèmes ».

Et en vue d'améliorer davantage de la modulation multi-trajet, nous avons considéré la combinaison des structures d'estimation avec les structures neuronales proposées.

D'une manière générale, nous avons eu l'occasion d'introduire des notions générales sur les systèmes de communications sans fil OFDM, telles que les modèles des canaux de transmissions, les modulations numériques et notamment le bruit et l'interférence entre symboles qui représentent des vrais problèmes.

De même, Nous avons donné un aperçu sur les estimateurs classiques (LS et LMMSE) et nous avons testé leurs performances par rapport aux courbes du taux d'erreurs binaires (BER).

La mise en œuvre des réseaux de neurones profonds (DNN) dans le contexte d'estimation est réalisée après avoir donné un aperçu sur leurs structures et leurs différents algorithmes d'apprentissage.

En tenant compte du type du réseau de neurones et des algorithmes d'apprentissage utilisés, la comparaison des différents estimateurs considérés dans notre travail a montré une énorme supériorité en performances de l'estimateur à base de l'apprentissage profond (DL), de par son niveau d'erreur quadratique moyenne MSE (le plus faible), et son BER (le plus réduit).

Cependant, l'éventuelle simulation à l'aide du langage de programmation python 3.7.4 en temps réel de ces techniques d'estimation nécessite une étude plus approfondie en tenant compte de toutes les contraintes de l'environnement de calcul considéré et des contraintes du temps.

Nous espérons que ce travail modeste ouvre les portes vers plus de recherches dans le domaine d'inclusion de Deep Learning dans l'amélioration des performances des systèmes de communications sans fil OFDM et dans les télécommunications en général.

Bibliographie

- [1] **Henrik Schulze, Christian Lüders. Scholtz**, "Theory and Applications of OFDM and CDMA". Edition J. Wiley and sons, 2005
- [2] **R.V. Née & R. Prasad**, OFDM for Wireless Multimedia Communications, Artech House Pubshers, 2000.
- [3] **R.W. Chang, and R.A. Gibby**, "Theoretical Study of Performance of an Orthogonal Multiplexing Data Transmission Scheme," IEEE Transactions on Communications, 16, 4, pp. 529-540, 1968.
- [4] **S. B. Weinstein et P. M. Ebert**, Data transmission by frequency-division multiplexing using the discrète Fourier transform, IEEE Transactions on Communication Technology, Vol. COM-19, No 5, pp. 628-634, Oct. 1971.
- [5] **Peled, A. Ruiz, A**, Frequency domain data transmission using reduced computational complexity algorithms, ICASSP'80, avril 1980, volume 5, pp 964-967..
- [6] **Hirosaki, B**, An Analysis of Automatic Equalizers for Orthogonally Multiplexed QAM Systems, IEEE Transactions on Communications, janvier 1980, volume 28, issue 1,pp 73-83.
- [7] **MiJiammad Imadur Rahman, Suvra Sekhar Das, Frank H.P.Fitzek**, "OFDM Based WLAN Systems," Technical Report R-04-1002; v1.2 ISBN87-90834-43-7 ISSN0908-1224, Aalborg University 2004.
- [8] **ANSI**, "Network and Customer Installation Interfaces — Asymmetric Digital Subscriber Line (ADSL) Metallic Interface," ANSI standard T1.413-1995.
- [9] **VDSL Alliance**, " VDSL Alliance SDMT VDSL Draft Standard proposai," ANSI Contribution T1E1.4/97-332, 1997.
- [10] **Matthieu Gautier**. « Algorithmes et architectures de récepteurs pour les systèmes multi porteuses par paquets d'ondelettes. » Traitement du signal et de l'image. Institut National Polytechnique de Grenoble- INPG, 2006. Français.
- [11] **Ben Jemâa Ahmed Bassem** :« étude comparative des canaux WSSUS en standard DVB » université de Tunis el Manar Soutenu le 4 décembre 2004 V <https://fr.scribd.com/doc/67439060/2/I-2-Principe-de-la-modulation-multi-porteuses>

- [12] **D. Prêle** : « SQUIDS et Méthodes de Multiplexage ». École thématique. Détection de Rayonnements à Très Basse Température (Fréjus) 6ième école thématique du 11 au 15 mai 2009,
- [13] **Khouni Sadika** : «Simulation et Optimisation D'un Réseau GSM en utilisant la Technologie OFDM ». Mémoire Magister électronique, université Ferhat Abbas-Sétif, 2010
- [14] **Glavieux Alain**, Livre : « Introduction Communications numériques ».2eme Édition : Dunod Paris Masson. Aout 2007,
- [15] **Simon Haykin**, Livre: « Introduction to Analog and Digital Communications ». Edition: Phoenix Color Corp, 2007
- [16] **MORI, Y.** « Electronique pour le traitement du signal, volume 2-Notions de signal et de bruit ». Edition: Hermes, Lavoisier, Paris, 2006.
- [17] **Xu Zhang**: «Modeling & Performance Analysis of QAM-based COFDM System», University of Toledo August 2011
- [18] **BAOUNI ABDELKHALEK**, « Estimation du Canal et Elimination des Interférences ICI dans les Communications Mobiles avec Modulation OFDM », MEMOIRE Présenté pour obtenir le diplôme de Magister, UNIVERSITE MENTOURI CONSTANTINE, Disponible sur : <https://fr.scribd.com/doc/242265896/Baouni-A-pdf>
- [19] **Mohamed IBNKAHLA.** « Applications of neural networks to digital communications », Signal Processing 80, pp 1185-1215, 2000.
- [20] **Pierre GRUYER, Simon PAILLARD**, “Modélisation d’un modulateur et démodulateur OFDM,” Univ. Bretagne, vol. 12, pp. 1–22, 2005.
- [21] **MathuranathanViswanathan** « Digital modulations using Matlab ebook edition », Build Simulation Models from Scratch, juin 2017.
- [22] **Alok Pandey** « Comparative Study of LMS and NLMS Algorithms in Adaptive Equalizer». International Journal of Engineering Research and Applications (IJERA). May-Jun 2012.
- [23] **F. Ben Salem**, «Réception particulière pour canaux multi-trajets évanescents en communications radio mobiles», Thèse de doctorat, Toulouse 3, 2002..
- [24] **P.Djiknavorian**, «MIMO pour les nuls», Laboratoire de Radio télécommunications et de Traitement du Signal, Janvier 2006.

- [25] **Manjushree Bhardwaj** « A Review on OFDM : Concept, Scope and its Applications », Department of electronics and instrumentation disponible sur: www.iosrjournals.org [26] **F. Rotella, P. Borne**, « Théorie et pratique du calcul matriciel », Editions TECHNIP, 1995.
- [26] **G.B Giannakis and all**, “Generalized multicarrier CDMA: Unification and linear equalization,” EURASIP Journal on applied signal Processing, pp. 743-756, May 2005.
- [27] **B. Le Saux**, “Estimation de canal pour système multi-antennes multi-porteuses,” Ph.D. dissertation, INSA Rennes, 2007.
- [28] **ETSI**, “Digital Radio Mondiale (DRM) ;System Specification,” ETSI, Tech. Rep. ETSI ES 201 980 V 3.1.1, August 2009.
- [29] **P. Fertl and G. Matz**, “Channel Estimation in Wireless OFDM Systems With Irregular Pilot Distribution,” IEEE Transactions on Signal Processing, vol. 58, no. 6, pp. 3180 – 3194, June 2010.
- [30] : **Vincent Savaux** « Contributions to multi-paths channel estimation in OFDM context» 2014
- [31] : **Yong Soo Cho , Jaekwon Kim , Won Young Yang , Chung G. Kang** “MIMO-OFDM WIRELESS COMMUNICATIONS WITH MATLAB”_, Copyright _ 2010 John Wiley & Sons (Asia) Pte Ltd, 2 Clementi Loop, # 02-01, Singapore 129809
- [32] **Morad Barkat**, Signal Detection and Estimation Second Edition
- [33] discrete-time model for digital communication over a frequency-selective rician fading WSSUS chanel **KW.Yip T-S.Ng**
- [34] **W. S. McCulloch and W. Pitts**. A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 5(4) :115–133, Dec. 1943.
- [35] **F. Rosenblatt**. The Perceptron, a Perceiving and Recognizing Automaton Project Para. Cornell Aeronautical Laboratory, 1957. 34
- [36] **K. Fukushima**. Neocognitron A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biological Cybernetics, 36(4) :193–202, Apr. 1980. 34
- [37] **D. E. Rumelhart, G. E. Hinton, and R. J. Williams**. Learning representations by back-propagating errors. Nature, 323(6088) :533–536, Oct. 1986. 35

- [38] **Y. LeCun**, « Les Enjeux de la Recherche en Intelligence Artificielle », Chaire Informatique et Sciences Numériques Collège de France, AU : 2015-2016.
- [39] **M. D. Youcef**, « Deep Learning pour la classification des images », Mémoire de Master, Université Abou Bakr Belkaid Tlemcen, Faculté des sciences, Département informatique, 2017.
- [40] Une source pour la traduction en apprentissage profond Yoshua Bengio, « Introduction aux algorithmes d'apprentissage profonds », sur Université de Montréal.
- [41] **Hilali, h.**, application de la classification textuelle pour l'extraction des règles d'association maximales. thèse de maitrise en informatique, université du québec à trois-rivières, trois-rivières, 2009.
- [42]-**G. Dreyfus, J. Martinez, M. Samuelides, M. Gordon, F. Badran, S. thiria et L.Herault**, « réseaux de neurones, méthodologies et application »; EditionEyrolles.2002.
- [43]- **A. Belgacem**, « Classification des signaux EGC avec un système-multi-agent neuronale.» mémoire de magister en informatique, université de Tlemcen 2012.
- [44]- **R. MAHADOU** « diagnostic industriel par neuro-floue application a un système de production » Thèse Ingénieur d'état en Informatique, Université de Batna 2007
- [45] **Rumelhart D.E. et McClelland J.L.**, Parallel Distributed Processing: Explorations in the Microstructure of Cognition, vol. 1, Cambridge, MIT Press, États-Unis, 1986.
- [46] **Werbos, P.J.**, "Beyond regression: New tools for Prediction and Analysis in the Behavioral Sciences". Thèse de Ph.D., Harvard University, Cambridge, ÉtatsUnis, 1974.
- [47]- **F. MEDJILI** « Modélisation par Réseaux de Neurones Artificiels (RNA) et commande Prédictive non linéaire d'une station de production d'eau froide » mémoire de magister en automatique, université de annaba 2010.
- [48]- **François B. et Michel V.** « Les réseaux de neurones artificiels» Presses Universitaire, Paris, 1996.
- [49]- **A. ASSOUM**, « étude de la tolérance aux aléas logiques des réseaux de neurones Artificiels », thèse de doctorat, institut national polytechnique de Grenoble, France.1997.
- [50]-**Olga RUSSAKOVSKY et al.**, « ImageNet Large Scale Visual Recognition Challenge », in : International Journal of Computer Vision (IJCV) 115.3 (2015), p. 211-252, DOI : 10.1007/s11263-015-0816-y.
- [51] Deng, l. and d. yu, deep learning methods and applications. 2014.

- [52] **Goodfellow, i., y. bengio, and a. courville**, deep learning. mit press, 2016.
- [53] Kaiming HE et al., « Deep Residual Learning for Image Recognition », in : arXiv e-prints, arXiv :1512.03385 (déc. 2015), arXiv :1512.03385, arXiv :1512.03385 [cs.CV].
- [54] **Christian SZEGEDY et al.**, « Going Deeper With Convolutions », in : The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015
- [55] **Bernhard SCHÖLKOPF, Alexander J SMOLA, Francis BACH et al.**, Learning with kernels : support vector machines, regularization, optimization, and beyond, MIT press, 2002.
- [56] **P.kyosti et al.**, « WINNER II chanel models » Eur , commission , Brussels, Belgium, Tech. Rep. D1.1.2 IST-4-027756-WINNER, Sep.2007.
- [57] **Hao Ye, Geoffrey Ye Li**, Fellow, IEEE, and **Biing-Hwang Juang**, Fellow, IEEE «Power of Deep Learning For Chanel Estimation and Signal Detection in OFDM Systems » Février 2018.