

الجمهورية الجزائرية الديمقراطية الشعبية

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE**

وزارة التعليم العالي والبحث العلمي

**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**

جامعة أبي بكر بلقايد - تلمسان

Université Aboubakr Belkaïd – Tlemcen –  
Faculté de TECHNOLOGIE



## **MEMOIRE**

Présenté pour l'obtention du **diplôme de MASTER**

**En** : Télécommunication

**Spécialité** : Réseaux et Télécommunications

**Par** :

ADDOU Sidi Mohammed Nazim  
ALLAM Abdessamad

**Sujet**

**LES RESEAUX NEURONES (IA) APPLIQUES A L'OPTIMISATION DES  
RESEAUX DE COMMUNICATION CELLULAIRES**

Soutenu publiquement, le 26 / 06 / 22 , devant le jury composé de :

M/HADJILA Mourad	MCA	Université de Tlemcen	Président
M/BAHRI Sidi Mohammed	MCB	Université de Tlemcen	Examineur
M/BENDIMERAD. F. Tarik	Professeur	Université de Tlemcen	Encadrant
M/BENDIMERAD. M. Yassin	MCA	Université de Bechar	Co-Encadrant
M/BENOSMAN. M. Meryem	Doctorante	Université de Tlemcen	Invitée

Année universitaire : 2021 /2022



# *Remerciement*

Nous remercions en premier lieu Dieu le tout puissant qui nous a aidés et qui nous a donné la force, le courage, la patience et la volonté pour terminer ce modeste travail.

Nous avons l'honneur et le plaisir d'exprimer nos sincères remerciements et nos profondes gratitudes vers notre Encadrant Professeur BENDIMERAD F. Tarik et notre Co-encadrant Mr BENDIMERAD M. Yassin pour leur patience, disponibilité, et surtout leur conseils et orientations au long de notre recherche. Nous remercions également Madame BENOSMAN M. Meryem, qui n'a pas hésité à nous aidé avec ses connaissances et conseils.

Nos remerciements s'adressent à tous les membres du jury Mr HADJILA Mourad et Mr BAHRI Sidi Mohammed pour l'honneur qu'ils nous ont fait en acceptant d'examiner et de juger ce travail.

Nous remercions tous nos enseignants et nos professeurs chacun avec son nom pour leur dévouement, leur patience et leur contribution à notre formation au cours des cinq ans passées à l'université de Tlemcen.

Un grand merci à nos familles, nos proches et nos amis qui nous ont toujours encouragées et qui nous ont aidés avec leur soutien, et à tous ce qui ont contribué et participé de près ou de loin à notre réussite.

Merci à toutes et à tous.

# Dédicace

*Avec un énorme plaisir et une immense joie que je dédie ce modeste travail  
aux être les plus chers de ma vie*

*A mes meilleurs parent ; vous étiez le système constructif le plus puissant, le  
mieux structuré, aucune dédicace, mot ne sauront exprimer ma gratitude, mon  
amour et ma considération pour les sacrifices que vous avez fait pour moi. Je  
vous remercie pour votre amour, J'espère qu'à travers ce travail j'ai pu vous  
rendre un petit pourcentage de tous ce que vous m'avez offert dans la vie*

*« Que dieu vous protège »*

*A mes chers frères ; avec tout l'amour que je vous porte je vous remercie  
pour le soutien et l'aide que vous m'avez donné.*

*A mon binôme, pour sa patience, sa collaboration et sa compréhension dans  
les moments difficiles.*

*A ma famille et à toute personne qui a participé de près ou de loin pour la  
réalisation de ce travail.*

*Abdessamad ALLAM*

# Dédicace

*A mes chers parents, pour leurs sacrifices et leurs soutiens moraux et physiques. Qui ont fait en sorte que l'amour de savoir soit un véritable credo pour leurs enfants.*

*Qui m'ont tant donné pour faire de moi ce que je suis.*

*Qui'ils trouvent ici le témoignage de ma profonde reconnaissance.*

*A mes sœurs à qui je souhaite un avenir brillant.*

*A mon binôme à qui je souhaite de la réussite dans des futurs travaux.*

*A ma famille, mes proches.*

*A mes amis et collègues.*

*Ce modeste travail est dédié pour vous en guise de reconnaissance.*

*Sidi Mohammed Nazim ADDOU*

## **Résumé**

Le développement rapide des réseaux d'opérateurs obligent les chercheurs à trouver des techniques bien plus optimisées que ceux qui existent maintenant en ce qui concerne la chaîne de transmission et la modulation. Les méthodes d'apprentissage profond peuvent offrir des résultats satisfaisants, les Auto-Encodeur sont l'un des modèles des réseaux de neurones artificiels qui peuvent être utilisées dans de divers secteurs dont le secteur des télécommunications. Dans ce travail, on implémente un système de modulation OFDM à base d'Auto-Encodeur en utilisant le langage de programmation Python avec ses bibliothèques (Keras, Matplotlib...) et pour voir si cette technique fournit des résultats similaires par rapport aux autres techniques tel que l'OFDM classique .

**Mots clé: OFDM, Apprentissage Profond, Réseaux de Neurones, Python**

## **Abstract**

The rapid development of operator networks is forcing researchers to find techniques that are much more optimized than those that now exist in terms of the transmission chain and modulation. Deep learning methods can offer satisfactory results; Auto-Encoders are one of the models of artificial neural networks that can be used in various sectors including the telecommunications sector. In this work, we implement an OFDM modulation system based on Auto-Encoder using the Python programming language with its libraries (Keras, Matplotlib...) and to see if this technique provides results similar to other techniques such as classic OFDM.

**Key words: OFDM, Deep Learning, Neural Network, Python**

## ملخص

يجبر التطور السريع لشبكات المشغلين الباحثين على إيجاد تقنيات محسنة أكثر من تلك الموجودة الآن من حيث سلسلة

الإرسال والتشكيل. يمكن أن تقدم طرق التعلم العميق (Deep learning) نتائج مرضية، والتشفير

التلقائي (Autoencoders) هو أحد نماذج الشبكات العصبية الاصطناعية التي يمكن استخدامها في مختلف القطاعات بما

في ذلك قطاع الاتصالات السلكية واللاسلكية. في هذا العمل، قمنا بتنفيذ نظام تعديل تعدد تقسيم التردد المتعامد

(OFDM) يعتمد على التشفير التلقائي باستخدام لغة برمجة Python مع مكتباتها (Keras ، Matplotlib ، ...) ولرؤية

ما إذا كانت هذه التقنية توفر نتائج مشابهة لتقنيات أخرى مثل OFDM الكلاسيكي.

**الكلمات المفتاحية: OFDM, Deep Learning, Neural Network, Python**

# Table des matières

Remerciement	I
Dédicace	II
Résumé	IV
Table des matières	VI
Liste des figures	X
Liste des tableaux	XII
Liste des acronymes	XIII
Introduction générale	1
 <b>CHAPITRE I : GENERALITES SUR LES COMMUNICATIONS NUMERIQUES</b>	
I.1.Introduction	2
I.2.Intérêt du numérique	2
I.3.Chaîne de communication	2
I.3.1.Convertisseur numérique analogique (CAN)	3
I.3.2.Codage source	3
I.3.3.Chiffrement	4
I.3.4.Codage canal	4
I.3.5.Multiplexage	4
I.3.6.Modulation	4
I.4.Multiplexage	4
I.4.1.Multiplexage en temps (TDMA : <i>time division multiple access</i> )	4
I.4.2.Multiplexage en fréquence (FDMA : <i>frequency division multiple access</i> )	4
I.4.3.Multiplexage en code (CDMA : <i>code division multiple access</i> )	5
I.4.4.Multiplexage en polarisation (PDMA : <i>polarisation division multiple access</i> )	5
I.5.Canal de transmission	5
I.6.Modulation	7



I.7.Types de modulation	8
I.7.1.Modulation d'Amplitude	8
I.7.2.Modulation de Fréquence	9
I.7.3.Modulation de Phase	10
I.8.Réseaux Cellulaire	10
I.9.Cinquième Génération (5G)	10
I.10.Architecture de la 5G	11
I.11.Objectif de la 5G	12
I.12.Sixième génération (6G)	12
I.13.OFDM (ORTHOGONAL FREQUENCY -DIVISION MULTIPLEXING)	13
I.14.Conclusion	13

## **CHAPITRE II : LA TECHNIQUE DE MODULATION OFDM (Orthogonal Frequency -Division Multiplexing)**

II.1.Introduction	14
II.2.Problématique	14
II.3.Historique	14
II.4.Principe et fonctionnement de l'OFDM	15
II.4.1.Spécification d'une transmission OFDM	15
II.4.2.Principe de la modulation OFDM	15
II.4.2.1.Principe de la de modulation	16
II.4.2.2.Principe de la de démodulation	17
II.4.3.Notion d'orthogonalité	18
II.4.3.1.Rappel mathématique	18
II.4.3.2.Orthogonalité	18
II.4.3.3.Porteuses orthogonales	19
II.5.Expression du signal OFDM en bande de base	20
II.6.Intervalle de garde	21
II.6.1.Préfixe cyclique(CP)	21
II.6.2.Zero Padding (ZP)	22
II.7.Schéma bloc d'un Système OFDM	22
II.8. Avantages et inconvénients de l'OFDM	23
II.8.1.Avantages de l'OFDM	23
II.8.2.Inconvénients de l'OFDM	23
II. 9.Conclusion	24

## CHAPITRE III : APPRENTISSAGE PROFOND ET LES RESEAUX DE NEURONES ARTIFICIELS

III.1.Introduction	25
III.2.Intelligence Artificielle (Artificial Intelligence)	25
III.3.Apprentissage automatique (Machine Learning)	25
III.3.1.Définition	25
III.3.2.Types d'apprentissage automatique	25
III.3.2.1.Apprentissage supervisé	25
III.3.2.2.Apprentissage non supervisé	26
III.3.2.3.Apprentissage semi-supervisé	26
III.3.2.4.Apprentissage par renforcement	26
III.4.Apprentissage Profond (Deep Learning)	26
III.5.Réseaux neurones artificiels (Artificial Neural Network)	27
III.5.1.Neurones biologiques	27
III.5.2.Neurone artificiel	27
III.5.3.Historique	28
III.5.4.Avantages et Inconvénients	29
III.5.5.Domains d'applications	29
III.5.6.Paramètre des réseaux neurones	29
III.5.7.Types des réseaux neurones	32
III.5.7.1.Perceptron	32
III.5.7.2.Perceptron Multicouche	33
III.5.7.3.Réseaux neurones convolutifs (CNN)	33
III.5.7.4.Auto-encodeurs (AE)	36
III.5.7.4.1.Principe de fonctionnement des auto-encodeurs	37
III.5.7.4.2.Types des auto-encodeurs	37
III.5.8.Types des réseaux neurones	37
III.5.9.Optimisation des réseaux neurones	42
III.5.9.1.Fonctions de perte (Loss Functions)	42
III.5.9.2.Complexité des réseaux neurones	45
III.5.9.3.Rétro-propagation (Back-propagation)	46
III.6.Conclusion	46

## **CHAPITRE IV : IMPLEMENTATION D'UN OFDM A BASE D'AUTO-ENCODEUR**

IV.1.Introduction	47
IV.2.Environnement et outils	47
IV.2.1.Environnement de développement	47
IV.2.2.Langages de programmation	47
IV.2.3.Bibliothèques utilisées	48
IV.3.Système OFDM classique	48
IV.4.Simulation OFDM classique	50
IV.4.1.Paramètres utilisées	50
IV.4.2.Résultats	50
IV.5.Système OFDM-AE	53
IV.6.Simulation système OFDM-AE	56
IV.6.1.Paramètres utilisés	56
IV.6.2.Résultats	56
IV.7.Conclusion	59
Conclusion Générale	60
Bibliographie	61

# Liste des figures

Figure I.1 : Chaîne de communications numériques.	3
Figure I.2 : Modèle simple d'un canal	5
Figure I.3 : câble coaxial	6
Figure I.4 : Paires torsadées	6
Figure I.5 : Fibre optiques	6
Figure I.6 : Signal d'information	7
Figure I.7 : Signal de porteuse	7
Figure I.8 : Signal modulé	8
Figure I.9 : Signal modulé en amplitude	9
Figure I.10 : Signal modulé en fréquence.	9
Figure I.11 : Signal modulé en phase	10
Figure I.12 : Architecture de la 5G	11
Figure I.13 : Evolution des réseaux cellulaire	13
Figure II.1 : OFDM signal orthogonal frequency division multiplexing	16
Figure II.2 : Schéma du modulateur OFDM	16
Figure II.3 : Schéma du démodulateur OFDM	17
Figure II.4 : Spectre en sortie du modulateur OFDM	18
Figure II.5 : Orthogonalité OFDM	19
Figure II.6 : Déférence entre OFDM et une technique -multi porteuse conventionnelle	20
Figure II.7 : Représentation fréquentielle et temporelle d'un signal OFDM	20
Figure II.8 : Intervalle de garde	21
Figure II.9 : Préfixe cyclique	21
Figure II.10 : Zéro Padding	22
Figure II.11 : Schéma bloc simplifié d'un émetteur-récepteur OFDM	22
Figure III.1 : Relation entre AI et ML et DL	26
Figure III.2 : Architecture d'un neurone biologique	27

Figure III.3 : Neurone Artificiel	27
Figure III.4 : un ANN simple	30
Figure III.5 : Fonction Sigmoidé.	30
Figure III.6 : Fonction ReLu	31
Figure III.7 : Fonction Softmax	31
Figure III.8 : Fonction Tanh	32
Figure III.9 : Architecture d'un Perceptron	32
Figure III.10 : Architecture d'un Perceptron Multicouche	33
Figure III.11 : Architecture de CNN	34
Figure III.12 : Couche de convolution	34
Figure III.13 : Couche de Pooling	35
Figure III.14 : Architecture d'un Auto-encodeurs	36
Figure III.15 : Représentation partie encodeur/décodeur	37
Figure III.16 : Types des réseaux neurones	38
Figure III.17 : La rétro-propagation	46
Figure IV.1 : Schéma des blocs de système OFDM	48
Figure IV.2 : Constellation 16-QAM	50
Figure IV.3 : Signal émetteur et récepteur	51
Figure IV.4 : Constellations reçues	51
Figure IV.5 : Densité Spectrale de Puissance de l'OFDM classique	52
Figure IV.6 : Taux d'erreur binaire (BER) de l'OFDM classique	52
Figure IV.7 : Architecture du système OFDM-AE	53
Figure IV.8 : Configuration de l'OFDM-AE	55
Figure IV.9 : Courbe de loss d'OFDM-AE	56
Figure IV.10 : Courbe d'accuracy d'OFDM-AE	57
Figure IV.11 : Constellation d'OFDM-AE	58
Figure IV.12 : Densité Spectrale de Puissance d'OFDM-AE	58
Figure IV.13 : Taux d'erreur binaire (BER) de l'OFDM-AE	59
Figure IV.14 : DSP d'OFDM classique/ DSP d'OFDM-AE	59

# Liste des tableaux

Tableau III.1 : L'évolution de DL	28
Tableau III.2 : Différents types de neurones	42
Tableau III.3 : Les formules des fonctions de pertes	44
Tableau IV.1: Paramètres de simulation d'OFDM classique	50
Tableau IV.2 : Paramètres de simulation d'OFDM-AE	56

# Liste des acronymes

## **A**

<b>AM</b>	<i>Amplitude Modulation</i>
<b>AMF</b>	<i>Core Access and Mobility Management Function</i>
<b>AE</b>	<i>Auto-Encoder</i>
<b>AI</b>	<i>Artificial Intelligence</i>
<b>ANN</b>	<i>Artificial Neural Network</i>
<b>AUSF</b>	<i>Authentication Server Function</i>

## **B**

<b>BER</b>	<i>Bit Error Rate</i>
------------	-----------------------

## **C**

<b>CDMA</b>	<i>Code Division Multiple Access</i>
<b>CP</b>	<i>Cyclic Prefix</i>
<b>CNN</b>	<i>Convolutional Neural Network</i>

## **D**

<b>DAB</b>	<i>Digital Audio Broadcasting</i>
<b>DL</b>	<i>Deep Learning</i>

## **F**

<b>FDMA</b>	<i>Frequency Division Multiple Access</i>
<b>FM</b>	<i>Frequency Modulation</i>

## **G**

<b>GNB</b>	<i>Next Generation NodeB</i>
<b>GSM</b>	<i>Global System for Mobile Communications</i>

## ***I***

***IoT***      *Internet of Things*

***IES/ ISI***      *Interférence Entre Symboles/ InterSymbol Interference*

## ***L***

***LTE***      *Long Term Evolution*

## ***M***

***MIMO***      *Multiple Input Multiple Outputs*

***MAE***      *Mean Absolute Error*

***ML***      *Machine Learning*

***MLP***      *Multilayer Perceptron*

***MSE***      *Mean Squared Error*

***MSLE***      *Mean Squared Logarithmic Error*

## ***N***

***NSSF***      *Network Slice Selection Function*

## ***O***

***OFDM***      *Orthogonal Frequency Division Multiplexing*

## ***P***

***PDMA***      *Polarisation Division Multiple Access*

***PCF***      *Policy Control Function*

***PM***      *Phase Modulation*

## ***Q***

***QAM***      *Quadrature Amplitude Modulation*

***QPSK***      *Quadrature Phase Shift Keying*



## **R**

**RF**            *Radio Frequency*

**RNN**        *Reccurent Neural Network*

## **S**

**SNR**        *Signal To Noise Rate*

**SMF**        *Session Management Function*

## **T**

**TFD**        *Discrete Fourier Transform (Transformation de Fourier discrète)*

**TFDI**      *Inverse Discrete Fourier Transform (Transformation de Fourier Discrète  
Inverse)*

## **U**

**UE**         *Unity Equipement*

**UDM**       *Unified Data Management*

**UMTS**      *Universal Mobile Telecommunication System*

**UPF**        *User Plane Function*

## **Z**

**ZP**         *Zero Padding*

## **#**

**4G**         *4<sup>eme</sup> Generation*

**5G**         *5<sup>eme</sup> Generation*

**6G**         *6<sup>eme</sup> Generation*

**INTRODUCTION**

**GENERALE**

Aujourd'hui et avec le développement rapide des systèmes de communication numérique et les divers réseaux cellulaires avec ces différentes générations qui se classifient et s'évaluent selon leurs services pour satisfaire les attentes exponentielles du marché. Les chercheurs du domaine visent toujours à trouver et développer des techniques de transmission bien meilleures que celles qui existent maintenant afin d'optimiser les systèmes et de garantir une expérience satisfaisante.

Parmi les techniques utilisées par les systèmes mobiles, la technique de modulation OFDM (Orthogonal Frequency Division Multiplexing) très connue pour les réseaux de communication sans fil, une technique qui consiste à diviser la bande de transmission en plusieurs sous-porteuses orthogonales. Son succès et popularité vient principalement de sa grande efficacité spectrale, ses performances en terme des effets de multi-trajet et des interférences entre symboles et porteuses.

L'utilisation des technologies de l'AI (Artificial Intelligence) et le DL (Deep Learning) augmente et s'intègre petit à petit dans tous les secteurs dont les télécommunications. Des réseaux de neurones artificiels (ANN) imités à partir des neurones biologiques humains, et des algorithmes avec une grande complexité capable de résoudre les plus difficiles des problèmes qui se posent dans la vie quotidienne généralement et dans le secteur des communications numériques plus spécialement en fournissant des résultats considérablement bons et efficaces.

Dans le cadre de notre projet de master, nous allons essayer de voir les performances des réseaux neurones artificiels dans l'optimisation des réseaux cellulaires en se basant sur la technique de modulation OFDM.

Les quatre chapitres qui constituent le mémoire sont comme suite : En premier chapitre nous allons décrire les notions de base de la communication numérique avec ses caractéristiques, la modulation, la cinquième génération des réseaux cellulaires et la sixième brièvement.

Dans le chapitre suivant, nous allons baser sur les principes de bases de la modulation OFDM avec ses différents paramètres et techniques, utilisation, avantages et inconvénients, et ses applications.

Le troisième chapitre se concentrera sur l'intelligence artificielle, l'apprentissage automatique et profond avec leurs notions, principes, types, caractéristiques, avantages et inconvénients, et applications...

Le dernier chapitre, présentera une implémentation sur python en utilisant les différentes techniques dont on a parlé dans le chapitre I et II. Une simulation de la modulation OFDM à base des réseaux neurones artificiels et une comparaison des résultats obtenus de la simulation avec une modulation OFDM classique.

**CHAPITRE I**

**GENERALITES SUR LES  
COMMUNICATIONS NUMERIQUES**

### **I.1.Introduction :**

Les communications numériques impliquent la transmission de messages d'un expéditeur à un ou plusieurs destinataires. L'expéditeur et le destinataire peuvent être des machines, des supports de stockage ou des personnes. Un message correspond à une séquence de symboles, et l'ensemble de tous les symboles possibles s'appelle l'alphabet. La communication est numérique lorsque le nombre de symboles de l'alphabet est fini, contrairement à la communication analogique où il existe une infinité de symboles possibles.

Si  $M$  est la taille de l'alphabet, le nombre de symboles qui le composent, alors on dit que la communication est  $M$ -aire. Si  $M=2$ , on parle de communication binaire [1].

### **I.2.Intérêt du numérique :**

La popularité croissante du numérique dans les communications est due à plusieurs facteurs.

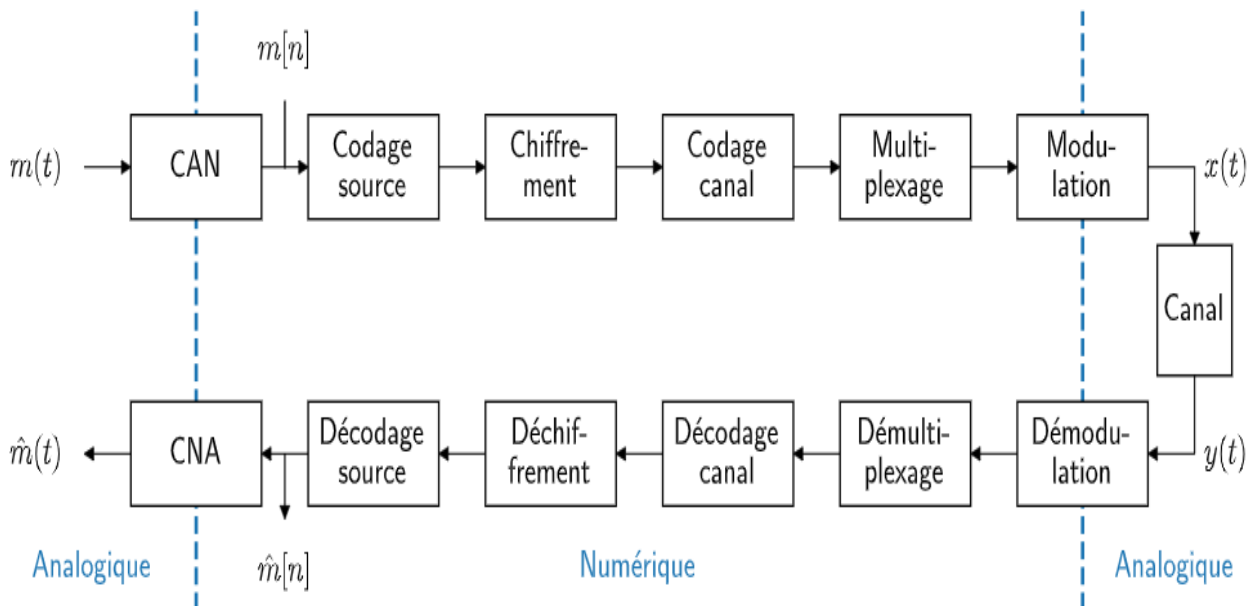
- Le numérique permet le routage (décision du chemin que prennent les messages) et l'adressage (définition de la destination) dans un système multiutilisateurs (comme pour le courrier électronique).
- Le chiffrement de données est plus simple et plus performant qu'en analogique.
- Le stockage et la lecture d'information sur un support physique (disque dur SSD par exemple) sont à la fois rapides et parfaits en comparaison à leur équivalent analogique (cassette par exemple).
- Les circuits d'électronique numérique sont généralement plus fiables et moins coûteux que les circuits analogiques équivalents.
- Les caractéristiques des systèmes de communication numérique peuvent facilement être mises à jour puisqu'il suffit de modifier le logiciel plutôt que le matériel [2].

### **I.3.Chaîne de communication :**

Les chaînes de communication numériques représentent différentes étapes du traitement de l'information. Elles relient l'émetteur au récepteur via un canal de transmission (canal). Un canal est un support (tel qu'un câble ou une fibre optique) qui transmet ou stocke des informations de message.

Par conséquent, comme le montre la figure I.1, le message  $m$ , qu'il soit sous forme analogique ( $m(t)$ ) ou déjà sous forme numérique ( $m[n]$ ), est convertie par différents blocs émetteurs et

devient finalement un signal analogique  $x(t)$ , et est publié. De son côté, le récepteur reçoit un signal analogique  $y(t)$ , différent de  $x(t)$  du fait d'interférences sur le canal de transmission. L'opération inverse de l'émetteur permet d'obtenir le message reçu  $\hat{m}$ , que l'on espère être le message envoyé [3].



**Figure I.1 :** Chaîne de communications numériques.

### I.3.1. Convertisseur numérique analogique (CAN) :

Transforme le message analogique en message numérique. Il effectue donc un échantillonnage et une quantification du signal portant le message analogique. Le CAN n'est bien sûr pas utile si le message est déjà sous forme numérique (comme c'est le cas d'un texte par exemple).

### I.3.2. Codage source :

Effectue une mise en correspondance entre l'alphabet du message et celui du canal. Par exemple, un texte dont les symboles sont les lettres et les signes de ponctuation est transformé en message binaire dont les symboles sont 0 et 1. Le codage source peut également effectuer une compression des données, c'est-à-dire réduire le plus possible la taille du message qui sera effectivement transmis.

**I.3.3.Chiffrement :**

Parfois appelé, à tort, « cryptage » consiste à modifier le message selon une certaine règle pour garantir son authentification ou pour le rendre incompréhensible si on ne possède pas la règle.

**I.3.4.Codage canal :**

Ajoute de la redondance dans le message ; le message est donc rallongé. L'objectif est de protéger le message des erreurs de transmission. Les codes utilisés permettent de détecter la présence d'erreurs dans le message reçu, et parfois même de les corriger.

**I.3.5.Multiplexage :**

Regroupe plusieurs messages différents pour qu'ils puissent être transmis sur le même canal. Ce bloc peut être situé à d'autres endroits sur la chaîne.

**I.3.6.Modulation :**

Convertit le message numérique en message analogique pour qu'il puisse être transmis via le canal, qui est un support physique et donc forcément analogique.

**I.4. Multiplexage :**

Le multiplexage consiste à partager les ressources entre plusieurs messages issus de différents émetteurs et récepteurs. On parle de MIMO (*multiple input multiple outputs*).

❖ Il existe quatre façons de multiplexer un signal :

**I.4.1.Multiplexage en temps (TDMA : *time division multiple access*) :**

Le temps est divisé en plusieurs créneaux, chacun étant affecté à un émetteur. Ainsi, les émetteurs envoient leur message les uns après les autres.

**I.4.2.Multiplexage en fréquence (FDMA : *frequency division multiple access*) :**

Chaque émetteur utilise une bande de fréquence propre.

**I.4.3. Multiplexage en code (CDMA : *code division multiple access*) :**

Chaque couple émetteur et récepteur dispose de son propre codage.

**I.4.4. Multiplexage en polarisation (PDMA : *polarisation division multiple access*) :**


Des polarisations orthogonales sont associées aux émetteurs (la polarisation correspond à l'orientation des champs électromagnétiques). On peut ainsi atteindre quatre messages en parallèle en utilisant les polarisations rectilignes et circulaires [4].

**I.5. Canal de transmission :**

Les canaux étant des dispositifs physiques, le signal qui y circule est toujours analogique, même si l'information reste codée par un message numérique. La transmission est souvent perturbée par deux phénomènes qui limitent la quantité de données pouvant être transmises [5] :

- du bruit, qui peut être électronique (produits par les composants), électromagnétique (dû aux rayons cosmiques) ou des interférences avec d'autres signaux (phénomène de diaphonie) ;
- des distorsions dues aux limitations physiques du canal ou aux imperfections des équipements :
  - atténuation du signal,
  - distorsion d'amplitude et de phase,
  - échos (trajets multiples),
  - largeur de bande du canal limité.

Pour ces raisons, un canal est souvent modélisé, en première approche, par un filtre passe-bas et un bruit additif :



**Figure I.2 :** Modèle simple d'un canal.



- Il existe plusieurs types de canaux, qui sont listés ci-dessous :




Figure I.3 : câble coaxial.




Figure I.4 : Paires torsadées





Figure I.5 : Fibre optiques.

**I.6.Modulation :**

La transmission des données dans les télécommunications d'un émetteur vers un récepteur se fait par un signal qui fait transporter l'information. Et pour communiquer à des distances grandes sans perturbation ou perte des données, les systèmes de communications utilisent une technique qui permet d'amplifier le signal et augmenté sa portée. La modulation.


Cette modulation est la transformation de la forme originale du signal à un signal adapté au canal de transmission, et pour cela deux signaux sont impliqué :

Le signal d'information (modulant) qui est le porteur de l'information à transmettre.




**Figure I.6 :** Signal d'information.

La porteuse est le signal qui prend en charge la transmission pour assurer l'envoi du message original vers sa destination, avec une fréquence supérieure que le signal d'entrée.



**Figure I.7 :** Signal de porteuse.

Après la modulation et l'intégration du signal d'information, le résultat est un signal modulé montré dans la figure I.8.



**Figure I.8 :** Signal modulé.

### **I.7.Types de modulation :**

Il existe plusieurs techniques de modulation dépendant des fréquences, amplitudes, phases..., plusieurs critères également pour le choix de la modulation tels que le cout, performance en termes de bruit, interférences, le débit, la bande utilisée.

Le signal porteuse est généralement un signal sinusoïdal qui se définit par

$$v(t) = A \sin(2\pi Ft + \Theta) \quad (I.1)$$

A :amplitude.

F :fréquence.

$\Theta$  :phase.

On ne change qu'un paramètre sur les trois, pour choisir le type de modulation. Qui sont :

- Modulation d'amplitude (AM).
- Modulation de fréquence (FM).
- Modulation de phase (PM)

#### **I.7.1.Modulation d'Amplitude :**

C'est la multiplication du signal d'origine (modulant) avec le signal de porteuse en variant l'amplitude ce dernier en fonction du signal d'information.

Soient :

- La porteuse :  $v(t) = A \sin(2\pi Ft + \theta)$  (I.2)

- Le signal modulant :  $S(t)$

- Le signal modulé :  $V(t) = [S(t) + A] \sin(2\pi Ft + \theta)$  (I.3)

La figure I.9 montre un exemple d'un signal modulé en amplitude.




Figure I.9: Signal modulé en amplitude.

### I.7.2. Modulation de Fréquence :

La FM consiste à transmettre le signal modulant toujours sur le signal de porteuse mais en modifiant la fréquence de la porteuse.





Figure I.10: Signal modulé en fréquence.

**I.7.3. Modulation de Phase :**

Pour ce cas, la phase de la porteuse est modifiée en fonction du signal modulant. La figure I.11 montre un exemple.



**Figure I.11:** Signal modulé en phase.

**I.8. Réseaux Cellulaire :**

Un ensemble de cellule connectées les uns avec les autre en formant une zone de transmission pour faire passer les données d'un point A à un point B. Les réseaux mobiles cellulaires permettent un usage simultané d'un nombre important d'utilisateurs en partageant un spectre de fréquence entre eux répartis dans différents cellules radio.

Le but est d'assurer la meilleure expérience de transmission des données sans pertes et avec une grande efficacité avec plusieurs techniques utilisées.

Ca a commencé avec la 1G et le GSM en passant par l'UMTS puis le LTE en arrivant aujourd'hui à la 5G, tout ça en apportant des améliorations en termes de débit, bande spectrale, fonctionnalités et domaines d'applications.

**I.9. Cinquième Génération (5G) :**

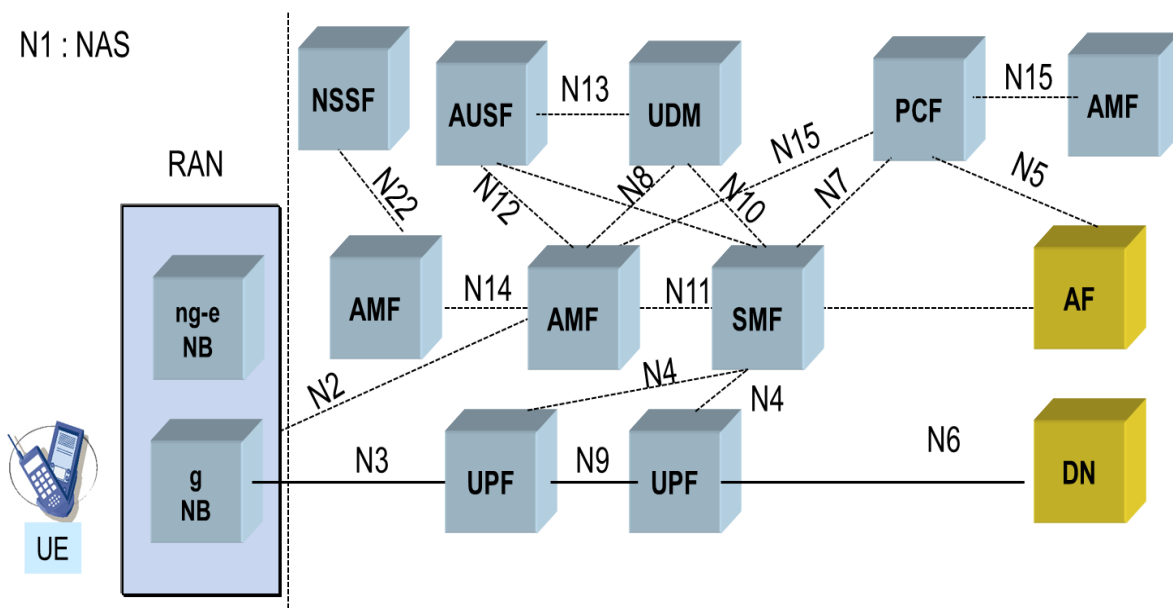
Aujourd'hui, avec le développement rapide de la technologie et les différents larges besoin des usagers, les demandes des bonnes performances et rapides augmentent jour après jours. Toutes les générations précédentes (1G, 2G, 3G, 4G) ont été conçu pour garantir des applications bien spécifiques, Pour cette 5G c'est différent en terme de rapidité, efficacité, performance en générale. Et surtout la nouvelle apparition qui s'accompagne avec cette génération c'est les objets communicants connectés avec les utilisateurs ou l'Internet des objets (IoT).

La nouvelle génération ne s'intéresse pas seulement par les divers soucis des opérateurs et réseaux mobiles mais elle vise d'autres perspectives plus grandes en visant à simplifier et faciliter la vie quotidienne. L'objectif principal est de se diriger vers une société entièrement connectée, cela permet une disponibilité partout et à n'importe quel moment.

L'idée derrière la 5G est plus grande qu'une simple augmentation de vitesse ou de capacité des réseaux..., la cible est plutôt l'intégration des grandes secteurs important tels que la santé, l'éducation, l'industrie avec cette technologie sous la couverture d'une société entièrement connectée.

### I.10. Architecture de la 5G :

La figure I.12 montre l'architecture de la 5G qui se compose de deux parties, une partie radio (RAN) et la deuxième est le réseau cœur [6].



**Figure I.12 :** Architecture de la 5G.

- UE : Equipement de l'utilisateur.
- GNB/ ng-eNB : la station de base/ station de base de nouvelle génération.
- AMF : Fonction de gérer la mobilité et d'accès.
- SMF : Fonction de gérer les sessions.
- UPF : Fonction de gérer les plan de transport.
- PCF : Contrôle de flux au niveau de SMF et AMF.

- UDM : Base de données contient les infos des utilisateurs.
- AUSF : Service d'authentification.
- NSSF : Réseau de sélection de slice.
- Nx : Représentes les interfaces entre les entités.

### **I.11.Objectif de la 5G :**

La 5G vise à être plus présente et à s'intégrer dans les domaines importants, et de faire quelques changements par rapport aux générations précédentes [7]:

- L'intégration dans le domaine de l'automobile et des véhicules connectés.
- L'intégration dans les technologies des maisons intelligentes.
- L'intégration dans la médecine et les opérations assistées à distance
- L'harmonisation du spectre de fréquence.
- L'utilisation des cellules de plus en plus petite.

### **I.12.Sixième génération (6G) :**

Une génération en cours de déploiement qui n'a pas encore vu le jour mais qui promet d'offrir une connectivité et performance immense comme avec la 5G.

Selon les estimations la 6G va toucher tout les aspects de la société et va être une réelle révolution surtout dans les secteurs de l'intelligence artificielle et apprentissage profond et automatique [8].

Ce qui est certain c'est que l'AI et le ML vont jouer un grand rôle dans l'optimisation de réseau 6G, et vont être l'acteur principal dans le développement et l'apparition de cette technologie.

L'AI peut contribuer dans ce développement dans des cas comme l'estimation des canaux, le codage des canaux, l'optimisation d'énergie, l'allocation de spectre, management des performances de réseau...

Cette 6G technologie va être présente partout comme le montre la figure I.13 qui expose l'évolution des réseaux cellulaire de la 1G à la 6G.

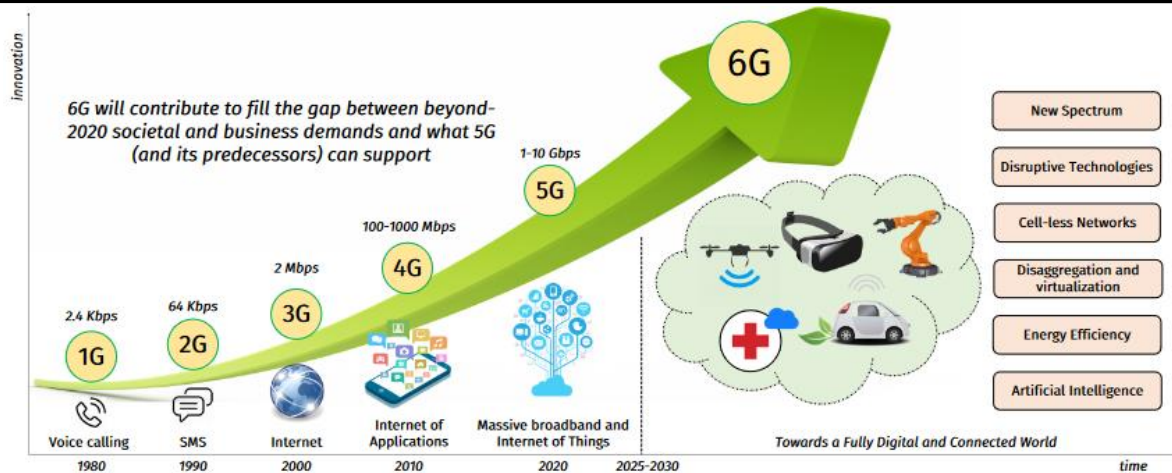


Figure I.13 : Evolution des réseaux cellulaire [9].

### I.13.OFDM (ORTHOGONAL FREQUENCY -DIVISION MULTIPLEXING):

L'une des techniques de modulation les plus utilisées, qui représente une évolution des précédentes techniques de multiplexage par division de fréquence (FDM), une technique qui se base sur l'orthogonalité des porteuses pour une meilleure efficacité spectrale. Apparue à la fin des années 1980 pour les consommateurs et elle est utilisée depuis pour les réseaux sans fils et les réseaux cellulaire en générale [10].

### I.14.Conclusion :

La transmission numérique consiste à transmettre des séquences de symboles appartenant à un alphabet connu, qui représentent l'information utile grâce à une opération de codage. Les télécommunications numériques sont plus fiables que les télécommunications analogiques d'autrefois. Les télécommunications numériques comportent trois aspects : l'aspect hardware (conception électronique des antennes), l'aspect protocoles et réseaux (couche logique) et l'aspect traitement du signal (couche physique). Ce chapitre n'aborde que le troisième aspect. Il couvre les questions de modulation, de démodulation, et d'évaluation des taux d'erreurs de transmission

Dans le prochain chapitre, on va présenter la modulation OFDM d'une manière générale.



# **CHAPITRE II**

## **LA TECHNIQUE DE MODULATION OFDM (Orthogonal Frequency -Division Multiplexing)**

---

**II.1.Introduction:**

L'OFDM (Orthogonal Frequency Division Multiplexing) est utilisé dans les réseaux sans fil et cellulaires et la télévision numérique. Il s'agit de transmettre des données en parallèle sur un grand nombre de sous-porteuses. Cet article montre comment ce transfert peut se faire simplement à partir d'une transformée de Fourier, et comment obtenir l'orthogonalité entre sous-porteuses. Il traite des avantages et des problèmes de l'OFDM dans les systèmes radio et des techniques pour les compenser. Enfin, les configurations OFDM pour différents systèmes radio sont brièvement décrites [11].

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 [12]. Pour obtenir une efficacité spectrale élevée, les réponses fréquentielles des sous-canaux sont en partie non disjointes mais orthogonales, d'où l'appellation OFDM.

Dans ce chapitre, nous aborderons la modulation OFDM, en commençant par les principaux enjeux de cette modulation, puis les principes de fonctionnement, et enfin leur mise en œuvre numérique.

**II.2.Problématique :**

La transmission du signal RF est effectuée sur un canal qui représente le support Physique. Si la chaîne ne le fait pas, les limitations physiques de ce support limitent sa transmission numérique se comporter différemment sur la bande, puis appeler un canal Optionnel. Le signal est alors déformé lors de la transmission et les données sont dispersées dans Cause temporelle entre symboles interférents.

La présence de trajet multiple aggrave ce phénomène de sélectivité en fréquence du fait que le signal peut subir en zone urbain de nombreuse réflexion. La réception sera un ensemble d'échos d'amplitudes sur des retards variables. Dans le cas d'un canal radio mobile cette problématique de canal a trajet multiple critique.

**II.3.Historique :**

La modulation multi-porteuse a été introduite à la fin des années 50, sa première utilisation était dans des systèmes de communications hautes fréquences militaires.

Quelques années plus tard elle a été améliorée avec l'apparition du concept des signaux orthogonaux à bande limitée, concept que l'on appellera par la suite "Orthogonal Frequency Division Multiplexing" (OFDM) ou multiplex à division de fréquences orthogonales. La mise en œuvre de l'OFDM à l'époque consistait à utiliser des filtres de Nyquist [13]. Du fait de la complexité à générer des bancs de filtres de sinusoides, l'OFDM n'a pas tout de suite intéressé les industriels civils. 20 ans plus tard le schéma de modulation-démodulation a été simplifié avec l'utilisation de la transformée de Fourier discrète inverse (TDFI) à l'émission et de la TFD au niveau du récepteur, ce qui rend facile son implémentation numérique. Dans le milieu des années 1980, la technique OFDM a été développée dans les domaines industriels civils tels que le projet de radiodiffusion numérique DAB (Digital Audio Broadcasting).

## **II.4.Principe et fonctionnement de l'OFDM :**

### **II.4.1.Spécification d'une transmission OFDM :**

L'OFDM est un procédé de modulation qui consiste à répartir un train binaire à haut débit sur N sous-canaux orthogonaux à bas débit. Le terme modulation est un abus de langage dans le sens où il s'agit de répartir l'information sur N sous-porteuses en bande de base. La modulation à proprement parler, qui permet d'adapter le signal autour de la fréquence centrale, reste quant à elle, identique à celle utilisée dans les chaînes de transmission numériques classiques. C'est-à-dire les symboles vont être repartie sur un grand nombre de porteuse a débit faible, à l'opposé des systèmes conventionnels qui transmettent les symboles en série, chaque symbole occupe alors toute la bande passante disponible.

### **II.4.2.Principe de la modulation OFDM :**

Le principe de l'OFDM consiste à diviser sur un grand nombre de porteuses le signal numérique que l'on veut transmettre. Comme si l'on combinait le signal à transmettre sur un grand nombre de systèmes de transmission (exemple: des émetteurs) indépendants et à des fréquences différentes. Pour que les fréquences des porteuses soient les plus proches possibles et ainsi transmettre le maximum d'information sur une portion de fréquences donnée, l'OFDM utilise des porteuses orthogonales entre elles. Les signaux des différentes porteuses se chevauchent mais grâce à l'orthogonalité n'interfèrent pas entre elles [14].

Le principe fondamental de l'OFDM c'est l'orthogonalité des sous porteuses, les sous-porteuses sont choisies de manière à être orthogonal entre eux.

L'Orthogonalité signifie aussi élevé efficacité spectrale, venant d'utiliser pleinement la bande passante disponible.

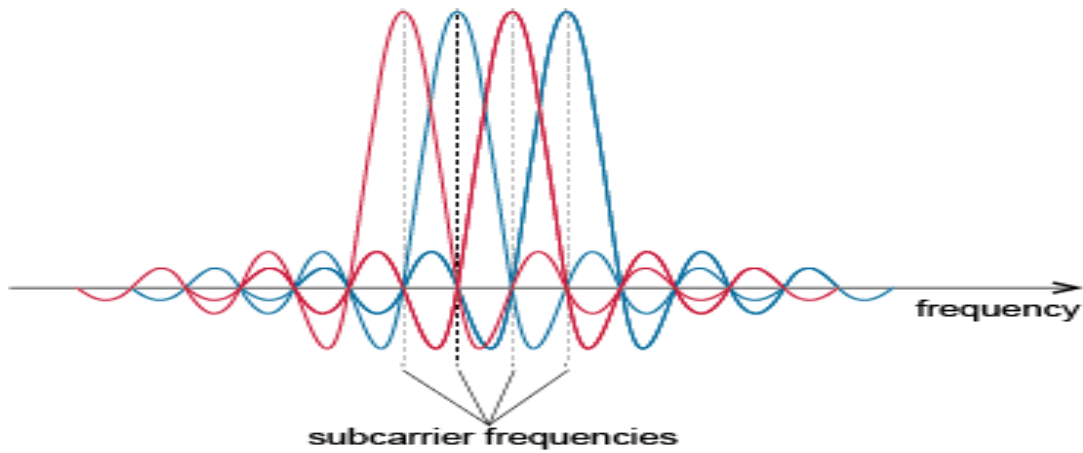


Figure II.1: OFDM Signal Orthogonal Frequency Division Multiplexing (OFDM)

**II.4.2.1.Principe de la de modulation :**

Afin de réparer les données à transmettre sur N porteuses, les symboles doivent être groupés par N paquets [15]. Ces symboles sont fournis au pluriel. Le signal de constellation, généralement de type QAM ou PSK, est modulé par la k ième séquences de symboles des N séquences.  $C_k$  Forme complexe du signal porteur modulé du train K. L'assemblage des symboles OFDM donne le signal total S(t).

$$\sum_{k=0}^{N-1} C_k e^{j2\pi f_k t} \tag{II.1}$$

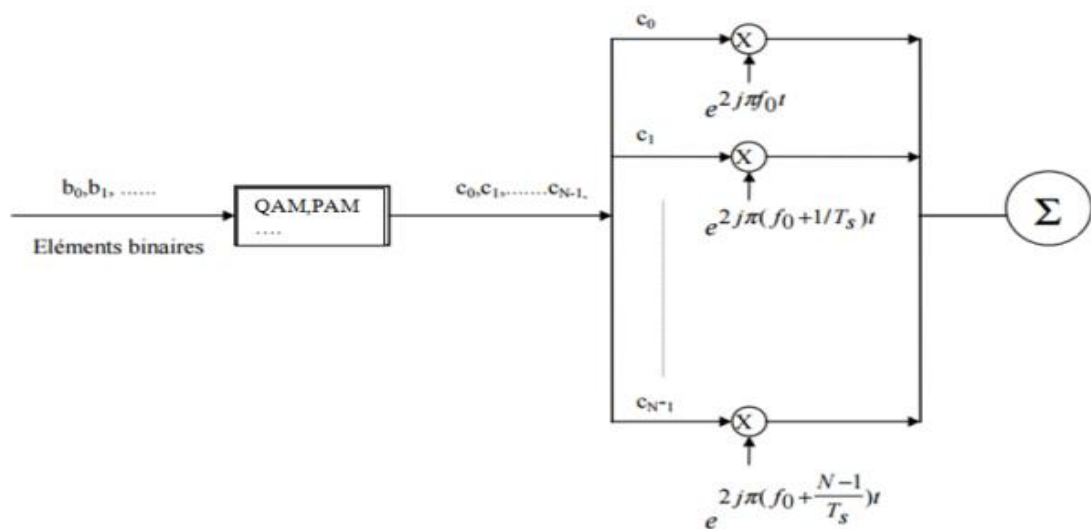


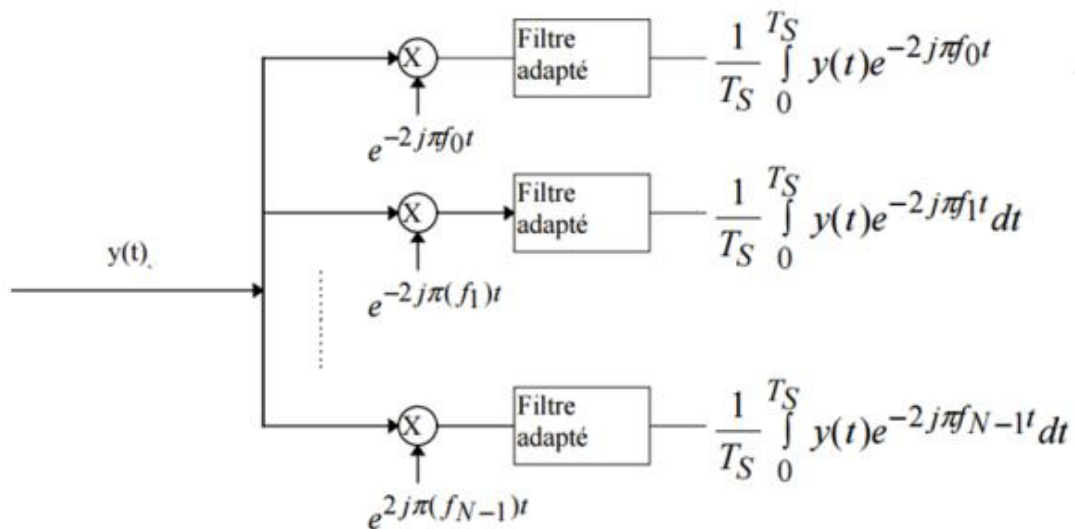
Figure II.2 : Schéma du modulateur OFDM

**II.4.2.2.Principe de la de démodulation :**

Le signal au récepteur s'écrit sur une durée de symbole  $T_s$  :

$$Y(t) = \sum_{k=0}^{N-1} C_k \cdot H_k(t) e^{j2\pi f_k t} \quad (\text{II.2})$$

- $H_k(t)$  la fonction de transfert du canal qui varie lentement.
- La démodulation classique consisterait à démoduler le signal suivant les  $N$  sous- porteuses suivant la figure II.3.




**Figure II.3 :** Schéma du démodulateur OFDM.

**II.4.3. Notion d'orthogonalité :****II.4.3.1. Rappel mathématique :**

L'orthogonalité de deux fonctions complexes  $f(t)$  et  $g(t)$  dans un l'intervalle  $[a, b]$  est donnée par l'expression mathématique suivante :

$$\int_a^b f(t) \cdot g(t) = 0 \quad (\text{II.3})$$

L'orthogonalité est la propriété fondamentale qui permet de transmettre des signaux d'informations multiples dans un même canal et de les détecter sans interférence [16].



**Figure II.4 :** Spectre en sortie du modulateur OFDM


**II.4.3.2. Orthogonalité :**

La technique de modulation OFDM autorise un fort recouvrement spectral entre les sous porteuses.

Cependant, les porteuses doivent respecter une contrainte d'orthogonalité dans les domaines temporel et fréquentiel au même temps pour un bon fonctionnement.

L'orthogonalité se réalise si l'espace entre deux fréquence adjacentes  $F_n = 1/T_n$ .

En effet chaque symbole moduler par une porteuse pendant une fenêtre rectangulaire de durée temporelle, sinus cardinal représente sous spectre en fréquence.



**Figure II.5 :** Orthogonalité OFDM.

Par conséquent, les autres sous-porteuses ne seront pas brouillées, ce qui est la valeur autorisée de chevauchement spectral et d'occupation optimale du spectre pour différentes porteuses. On doit sélectionner à la fin le nombre de sous-porteuses  $N$  vérifiant les deux conditions d'origine  $T_s \gg T_m$  pour pouvoir considérer des canaux plats, tandis que  $T_s \ll 1/B_d$ .

### II.4.3.3. Porteuses orthogonales :

Nous définissons l'efficacité spectrale comme étant le débit binaire transmis par unité de fréquence. Dans une transmission de type OFDM, le choix de l'écart entre les porteuses va influencer sur cette efficacité spectrale. Plus l'espacement entre porteuses est grand, plus nous avons besoin de bande passante pour transmettre un même débit, et plus l'efficacité spectrale diminue. Pour garantir une efficacité spectrale optimale, il faut que les fréquences des porteuses soient les plus proches possibles, tout en garantissant une absence d'interférence entre les informations qu'elles transportent afin que le récepteur soit capable de les restituer. Cette condition est vérifiée :

- dans le domaine temporel si les formes d'onde du signal OFDM reçu  $g(t)$  et du récepteur  $f(t)$  sont orthogonales.
- dans le domaine fréquentiel si les spectres des porteuses s'annulent mutuellement deux à deux, avec  $G(f) = \text{TF}[g(t)]$ .

Alors on parle alors de condition d'orthogonalité des porteuses [17].

La représentation du schéma qui montre le rôle de l'orthogonalité pour améliorer l'efficacité spectrale.

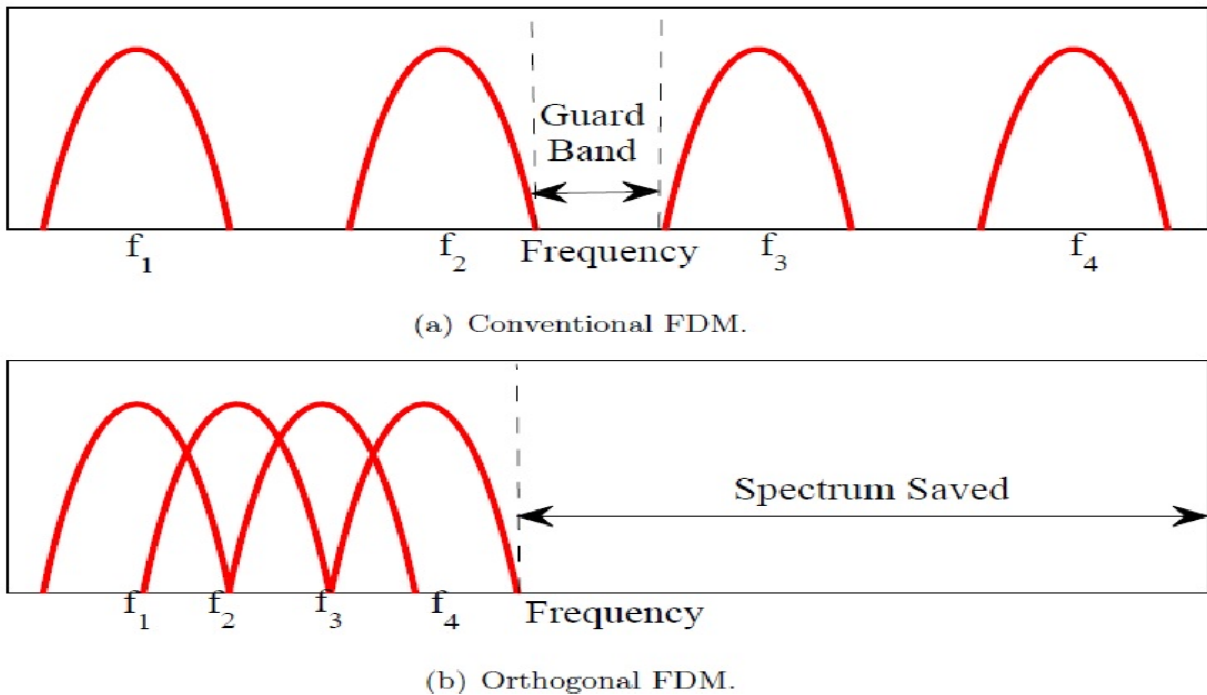


Figure II.6 : Différence entre OFDM et une technique -multi porteuse conventionnelle

**II.5.Expression du signal OFDM en bande de base :**

L'OFDM a comme principe de transmettre les informations sur plusieurs porteuses orthogonales entre elles, ainsi le spectre du signal présente une occupation optimale de la bande allouée [18]. Comme dans la Figure II.7, l'OFDM divise le canal en cellules selon les axes du temps et des fréquences. A chaque cellule fréquence/temps une porteuse dédiée est attribuée.

L'information à transmettre est répartie sur l'ensemble de ces porteuses, modulée chacune à faible débit par une modulation du type QPSK ou QAM. Un symbole OFDM comprend l'ensemble des informations contenues dans l'ensemble des porteuses à un instant 't' [19].





Figure II.7 : Représentation fréquentielle et temporelle d'un signal OFDM.



**II.6. Intervalle de garde :**

Les signaux OFDM sont transmis à des intervalles égaux, ils doivent parcourir un certain trajet pour atteindre le récepteur. Dans le cas d'un canal multi-trajets, un symbole transmis prend différents retards pour arriver au récepteur à cause des différents chemins de propagation, ce qui cause des étalements temporels différents. La prolongation de la durée des symboles fait chevaucher les symboles entre eux, ce provoque une interférence entre symboles (IES).


Les symboles subissent des échos et un symbole émis arrive au récepteur sous la forme de plusieurs symboles atténués, retardés. Un symbole émis pendant une période de  $iT_s$  peut être superposé à un écho provenant du symbole émis à la période  $(i-1)T_s$ , donc il va se produire des interférences entre symboles. Pour éviter ces interférences, on ajoute un intervalle de garde d'une durée  $T_g$ . Chaque symbole est précédé par une extension périodique du signal lui même, la durée du symbole totale transmis est alors  $T = T_s + T_g$ , afin que les interférences soient éliminées [20].



**Figure II.8 :** Intervalle de garde

**II.6.1. Préfixe cyclique (CP) :**

Le CP a comme principe de copier une partie de la fin d'un symbole OFDM dans son début comme il est illustré dans la figure II.9. Contrairement dite, le CP consiste à copier une partie du début d'un symbole OFDM dans sa fin. Il s'agit de récupérer une partie des informations à transmettre et d'insérer ces informations en début du bloc.



**Figure II.9 :** préfixe cyclique

Ainsi, le préfixe cyclique permet d'éviter les interférences causées par les effets des trajets multiples et maintenir l'orthogonalité temporelle entre les symboles [21].

**II.6.2.Zero Padding (ZP) :**

Insérer des zéros au lieu d'intervalle de garde et aucun signal est transmise pendant l'intervalle de garde, appeler zero-padding (ZP-OFDM).

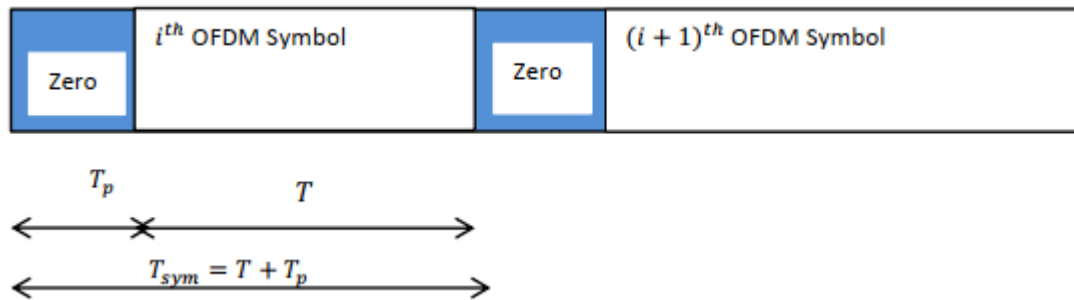


Figure II.10 : Zero Padding.

Le type d'intervalle de garde CP est couramment utilisé.

**II.7.Schéma bloc d'un Système OFDM :**

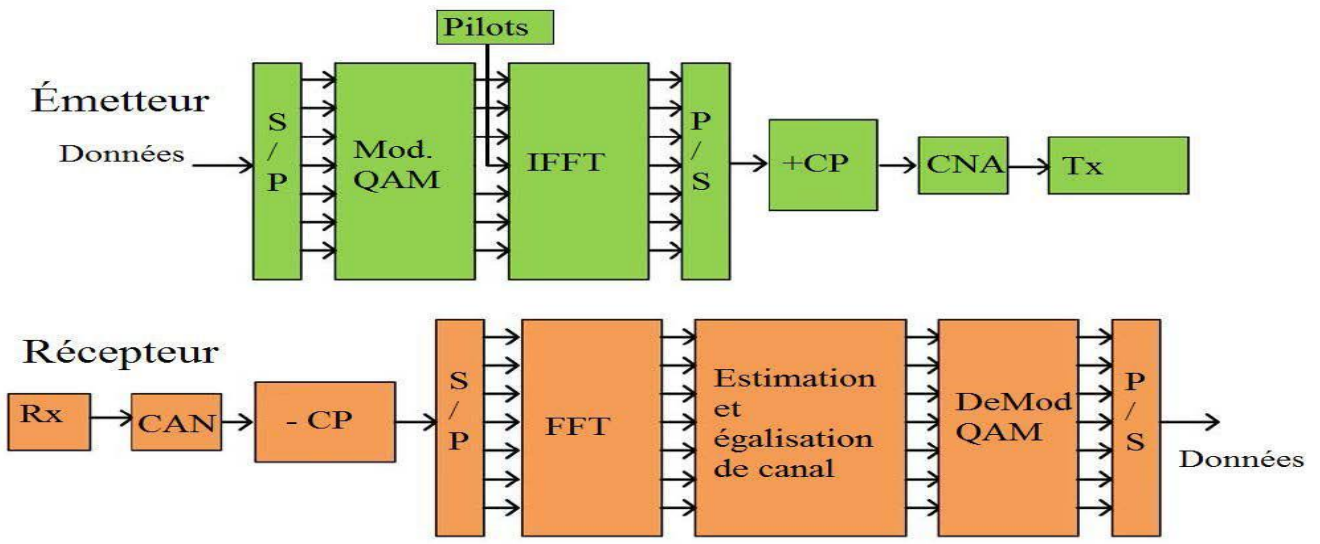


Figure II.11 : Schéma bloc simplifié d'un émetteur-récepteur OFDM

- **Convertisseur série parallèle** : Fait la conversion des données séquentielles reçue en un flux composé de plusieurs éléments transmis simultanément.
- **Mappeur** : prend chaque symbole reçu et le rend vers une forme complexe selon le type de modulation.
- **Transformée de Fourier** : Les opérations mathématiques d'IFFT / FFT sont principalement utilisées pour convertir les signaux du domaine temporel vers le domaine fréquentiel et vice versa.

## II.8. Avantages et inconvénients de l'OFDM :

### II.8.1. Avantages de l'OFDM :

Les avantages de l'OFDM sont nombreux dont on va citer :

- L'efficacité spectrale : Avec OFDM, il est possible d'augmenter le nombre des sous-porteuses sans augmenter la bande de fréquence utilisé tant que l'orthogonalité entre les sous-porteuses est maintenue [22].
- Implémentation simple : grâce à l'utilisation de la transformée de Fourier et son inverse.
- Complexité réduite du récepteur : Une égalisation numérique moins complexe grâce à l'utilisation d'un grand nombre de sous-porteuses, et optimale grâce à l'utilisation de l'intervalle de garde (au prix d'une diminution du débit).
- Convenable pour les transmissions à haut débit.
- Robuste contre l'effet multi-trajet grâce à l'utilisation du préfixe cyclique.

### II.8.2. Inconvénients de l'OFDM :

La modulation OFDM à aussi des inconvénients comme :

- L'OFDM conventionnelle, utilise une forme d'onde rectangulaire parfaitement localisée en temps mais mal localisée en fréquence.

- 
- Une perte d'efficacité spectrale et une perte en débit de transmission due à l'intervalle de garde induit.
  - Pertes en efficacité, dues à l'ajout des sous-porteuses virtuelles dans le domaine fréquentiel ainsi que l'intervalle de garde dans le domaine temporel [23].

## II. 9. Conclusion :

Ce chapitre nous a permis de présenter l'évolution de la modulation multi porteuse OFDM, les besoins qui ont menés à l'apparition de cette technologie. L'OFDM est une technologie de communication populaire maintenant. Il est adopté par la norme de communication sans fil 4G. Par rapport à la technologie 3G, son succès repose sur son efficacité spectrale et la simplicité de sa mise en œuvre en FFT.

Cependant, les sous-porteuses virtuelles sont nécessaires pour réduire le débordement spectral des signaux OFDM en dehors de la bande de fréquence qui leur est réservée [24].

De même, l'ajout d'un intervalle de garde dans le domaine temporel est nécessaire pour lutter contre la dispersion chromatique causée par les trajets multiples. Les travaux en cours visent à réduire la perte d'efficacité spectrale due à l'utilisation de sous-porteuses virtuelles ainsi que les intervalles de garde pour répondre aux exigences des systèmes de communication sans fil 5G [25].

Dans le chapitre suivant nous allons présenter des généralités sur l'intelligence artificielle, les apprentissages profonds et automatiques avec leurs types et techniques et les différents types des réseaux neurones.

**CHAPITRE III**  
**APPRENTISSAGE PROFOND ET**  
**LES RESEAUX DE NEURONES**  
**ARTIFICIELS**

**III.1.Introduction :**

L'intelligence artificielle considérée comme une discipline scientifique à pour trouvé des solutions à des problèmes de grande complexité. L'apprentissage automatique un sous domaine de l'AI qui résolve des problèmes à l'aide de l'intervention humaine. L'apprentissage profond un sous domaine de ce dernier, qui se base sur l'utilisation des réseaux neurones artificiels et qui fonctionnent sans instructions ou interventions humaine.

Le chapitre III se concentre sur l'évolution des ANNs et DL, les différents modèles et techniques à connaître sur ce vaste domaine, le chapitre présente les notions importantes et donne une vision générale sur ces technologies gourmandes.

**III.2.Intelligence Artificielle (Artificial Intelligence) :**

Le principe de l'intelligence artificielle (AI) est d'utiliser un certain nombre de techniques qui vont permettre à la machine d'imiter une forme de l'intelligence réelle.

C'est une science dont le but est d'utiliser des machines pour faire des taches que l'homme utilise son intelligence pour les accomplir. Le terme d'intelligence artificielle est apparu en 1956 [26].

**III.3.Apprentissage automatique (Machine Learning) :****III.3.1.Définition:**

L'apprentissage automatique est une science moderne permettant de découvrir des répétitions dans un ou plusieurs flux de données et de faire des prédictions basées sur des statistiques. Évidemment, l'apprentissage automatique est basé sur l'exploration de données, ce qui permet à la reconnaissance de formes de faire une analyse prédictive.

L'apprentissage automatique révèle tout son potentiel dans des situations où des informations doivent être déterminées à partir d'ensembles de données vastes et diversifiés, appelés Big Data [27].

**III.3.2.Types d'apprentissage automatique:****III.3.2.1.Apprentissage supervisé :**

Dans ce cas là, les données sont étiquetées pour indiquer à la machine quel chemin doit rechercher. Le système est formé sur un ensemble de données étiquetées qui contient les informations que la machine doit déterminer. Les données peuvent même déjà être catégorisées comme le système le devrait. Cette méthode nécessite moins de données de formation que les autres méthodes et facilite le processus de formation car les résultats du modèle peuvent être comparés à des données déjà étiquetées. Cependant, l'étiquetage des données peut être coûteux [28].

**III.3.2.2.Apprentissage non supervisé :**

Contrairement au premier cas, les données ne sont pas étiquetées. La machine essaye d'explorer les données pour trouver les informations qu'elle cherche, en utilisant une grande quantité de donnée et des algorithmes spécial pour en extraire les caractéristiques requises pour trier et catégorisé les données. Son avantage principal c'est qu'elle peut traiter et utiliser les données non étiquetés d'une façon bien meilleure que les humains.

**III.3.2.3.Apprentissage semi-supervisé :**

C'est un mélange entre les deux premiers cas, on utilisant un ensemble de données étiqueté pendant l'entraînement pour guider la machine à partir d'un ensemble plus large de données non étiquetées. C'est une solution dans le cas où on à pas suffisamment de données étiquetées pour un apprentissage supervisé.

**III.3.2.4.Apprentissage par renforcement:**

On laisse la liberté à l'algorithme d'apprendre de ses erreurs pour arriver au résultat souhaité. L'algorithme utilisera plusieurs méthodes et chemins pour essayer d'atteindre le but.

**III.4.Apprentissage Profond (Deep Learning) :**

L'apprentissage profond est l'une des catégories principales de machine learning, qui lui-même fait partie de l'intelligence artificielle. Le DL c'est des algorithmes créé pour mimer les actions et l'intelligence du cerveau humain à l'aide des réseaux neurones artificielles. Ces modèles de DL fonctionnent correctement quand on leur fourni une large quantité de données (Big data) [29].




Figure III.1 : Relation entre AI et ML et DL.

**III.5. Réseaux neurones artificiels (Artificial Neural Network) :**

Le DL est basé principalement sur les réseaux neurones artificielles qui ont été inspiré par le fonctionnement et l'architecture des réseaux neurones biologiques.

**III.5.1. Neurones biologiques :**

L'élément de base que le système nerveux possède est le neurone, un cerveau en posséderait des milliards de neurones. Et les neurones eux même se compose de :

- **Corps cellulaire** : Chaque information recueillie par les synapses est acheminée vers cet élément.
- **Synapse** : Elle se trouve généralement entre la dendrite d'un neurone et l'axone d'un autre.
- **L'axone** : Responsable de la transmission de l'information, guidant les signaux électriques vers un autre neurone.
- **Dendrites** : Des extensions tubulaires fines qui forment une arborescence vaste autour du neurone.




Figure III.2 : Architecture d'un neurone biologique

**III.5.2. Neurone artificiel :**

C'est une imitation des neurones biologiques mais d'une façon simplifier et moins complexe que ces derniers. Ils sont aussi appelées « Perceptron ».




Figure III.3 : Neurone Artificiel.



Les neurones biologiques reçoivent leurs entrées à partir des autres neurones à l'aide des dendrites, pareil pour un perceptron qui reçoit ses entrées des autres perceptrons via des neurones d'entrée [30].

Les synapses font la liaison entre les neurones et les dendrites, les poids font la même chose entre les entrées et les perceptrons. L'axone est responsable de la transmission du signal de sortie, pour un perceptron c'est la valeur de sortie qui va devenir une entrée pour les autres perceptrons.

### III.5.3.Historique :

En cherchant réellement sur l'histoire de l'apprentissage profond et les réseaux on trouve qu'en 1957 c'était le début d'une révolution dans le domaine de l'intelligence artificielle et les réseaux neurones qui a commencé par les perceptrons de Franck Rosenblatt, et puis à partir des années 1980 c'était une nouvelle période pour le développement des réseaux neurones jusqu'à ce jours là [31].

Le tableau III.1 ci-dessous montre les étapes importantes dans l'évolution de DL.

1873	Alexander Bain	A introduit le neural grouping le premier exemple d'un réseau de neurones
1943	McCulloch and Pitts	L'introduction d'un modèle MCP qui est considéré comme l'ancêtre des ANNs
1949	Donald Hebb	Le père des ANNs a introduit une règle d'apprentissage de Hebb qui aidera à la fondation des ANNs
1958	Frank Rosenblatt	L'introduction du modèle de Perceptron
1974	Paul Werbos	Il a introduit la rétro-propagation (Back propagation)
1980	Kunihiko Fukushima	L'introduction de necocogitron, qui a inspiré les CNNs
1985	Hilton & Sejnowski	L'introduction de machine de Boltzmann
1986	Michael I. Jordan	L'introduction des réseaux récurrents (RNNs)
1990	Yann LeCun	Introduction de LeNet
2009	Salakhutdinov & Hinton	A introduit deep Boltzmann machine
2012	Geoffrey Hinton	Introduction de Dropout, une méthode pour l'entraînement des ANNs

Tableau III.1 : l'évolution de DL [32].

**III.5.4. Avantages et Inconvénients :****Avantages :**

- Une précision importante.
- Apprendre à partir des exemples et des entraînements contrairement aux autres algorithmes qui suivent des instructions.
- La tolérance au manque de donnée, Un manque dans les données d'entrée n'as pas une grande influence.
- S'adapte au plusieurs problèmes dans plusieurs domaines.
- Robustesse.

**Inconvénients :**

- Nécessite une très grande quantité de données.
- Un cout très élevé pour des résultats parfaits.
- Le temps d'apprentissage est assez long.
- Difficile à comprendre ce que se passe à l'intérieur des modèles.

**III.5.5. Domaines d'applications :**

Aujourd'hui cette technologie est présente un peu partout et peut être utile à travaille avec dans de nombreux secteurs, dont [33] :

- Domaine médical : Détection des cancers.
- Crypto : prédire les futures actions.
- Défense : identifications des signaux et des images, reconnaissance faciale.
- Industrie : contrôles des machines, auto-conduite des voitures.
- Communications cellulaire : Optimisations des systèmes.

**III.5.6. Paramètre des réseaux neurones :**

Un réseau neuronal à quatre paramètres importants qui influent sur les résultats final. La figure III.4 montre un exemple d'un modèle avec ces paramètres.




Figure III.4 : ANN simple

**Les couches:** généralement pour chaque modèle il existe trois couches, une couche d'entrée(X), une couche de sortie (O) et une ou plusieurs couches cachées(H).

**Les poids :** c'est un élément qui relie les neurones les uns avec les autres, ils contrôlent la force de la connexion entre les deux neurones.

**Les biais :** c'est un paramètre à valeur constante à ajouter, même quand toutes les entrées sont nulles les biais garantissent qu'il y aura toujours une activation dans le neurone [34].

Les biais et les poids sont des paramètres que l'algorithme les apprend lors de la phase d'apprentissage des ANNs.

**Les fonctions d'activations :** C'est des fonctions mathématiques importantes pour le comportement des neurones (lequel restera activé et lequel va être désactivé), Et pour ajouter la non-linéarité au réseau de neurones.

La fonction **Sigmoïde**: C'est l'une des fonctions les plus connus pour les ANNs, le travail de la fonction sigmoïde est de diminuer toutes les valeurs inférieure au zéro et les valeurs supérieure vers 1 [35].

La fonction s'écrit : 
$$f(z) = \frac{1}{1+e^{-z}} \quad (III.1)$$

avec z : la somme des valeurs d'entrée.




Figure III.5 : Fonction Sigmoïde.

La fonction **ReLU** : Une autre fonction très connue et utilisée est l'unité linéaire rectifiée (ReLU), une fonction non-linéaire également et elle rend les valeurs négatives des valeurs nulles, et les valeurs positives augmente linéairement [36].

La fonction se définit comme :  $f(z) = \max(0, z)$  (III.2)




Figure III.6 : Fonction ReLu.

La fonction **Softmax**: Utilisée généralement pour les classifications multi-classes, utilisée pour la couche de sortie. Qui s'écrit comme suit :

$$f(y_i) = \frac{e^{y_i}}{\sum e^{y_i}} \quad (\text{III.3})$$

avec les  $y_i$  sont les résultats produits par le réseau de neurone avant de lui appliqué une fonction d'activation [37].




Figure III.7 : Fonction Softmax.

La fonction **Tanh** (Tangente hyperbolique) : Une fonction qui se ressemble trop à la fonction Sigmoid, mais la différence est que la Sigmoid varie de 0 à 1 contrairement à la fonction Tanh qui varie de -1 à 1.

Plus la valeur d'entrée est positive plus la valeur de sortie serait proche de 1, et plus l'entrée est négative plus la valeur de sortie se rapproche de -1.

Sa formule s'écrit comme : 
$$f(y_i) = \frac{(e^z - e^{-z})}{(e^z + e^{-z})} \tag{III.4}$$




Figure III.8 : Fonction Tanh.

### III.5.7.Types des réseaux neurones :

#### III.5.7.1.Perceptron :

C'est la version mathématique d'un neurone biologique.

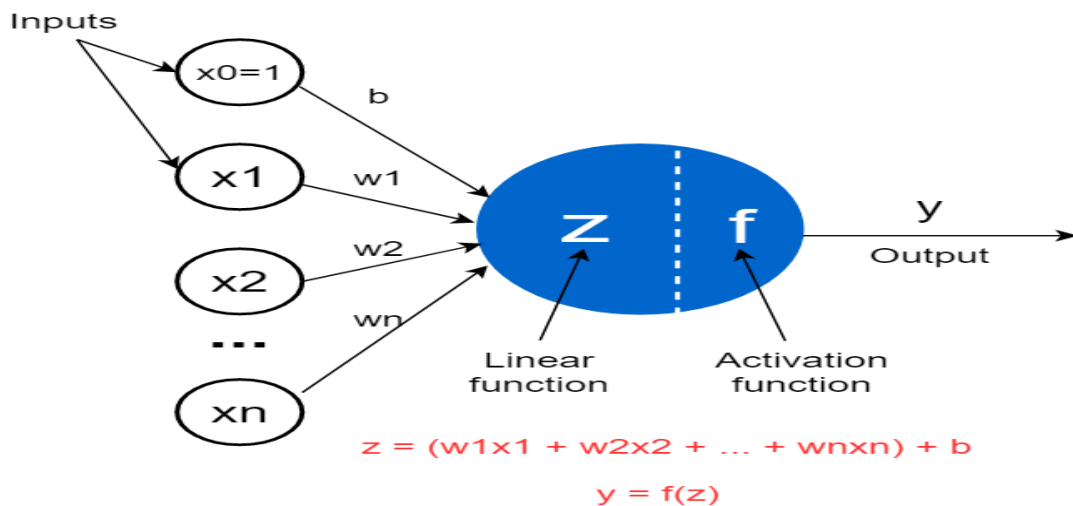


Figure III.9 : Architecture d'un Perceptron.

$x_n$  : Les données d'entrée  
 $w_n$  : Les poids  
 $b$  : Le biais

$f$  : La fonction d'activation  
 $y$  : La sortie  
 $z$  : la fonction linéaire

Le perceptron prend les  $X_n$  et les multiplie par les  $W_n$ , ajoutant une valeur de Biais, puis il calcule la fonction linéaire  $Z$ , enfin le passage par la fonction d'activation pour avoir une sortie  $Y$  [38].

La fonction  $Z$  est représentée par la formule suivante :

$$Z = \sum(X_n * W_n) + b \quad (\text{III.5})$$

La sortie  $y$  est également représentée par :

$$Y = F(Z) \quad (\text{III.6})$$

### III.5.7.2. Perceptron Multicouche :

C'est un réseau avec une couche d'entrée, une couche de sortie, une ou plusieurs couches cachées, avec tous les neurones d'une couche sont connectés avec les neurones de la couche suivante. Ces perceptrons multicouches ont le pouvoir de traiter des données non séparables linéairement, c'est l'un des réseaux neurones le plus utilisé.

La figure III.10 ci-dessous montre l'architecture d'un réseau MLP.




Figure III.10 : Architecture d'un Perceptron Multicouche

### III.5.7.3. Réseaux neurones convolutifs (CNN):

Pour les traitements d'images les CNNs seront votre meilleur choix comme réseaux de neurones, avec une architecture riche et contient plusieurs opérations sur les données, ils donnent les meilleurs résultats dans ce domaine de traitement d'image. Pour son architecture on peut l'avoir divisé en deux parties, la première partie de convolution et la deuxième pour la classification [39].

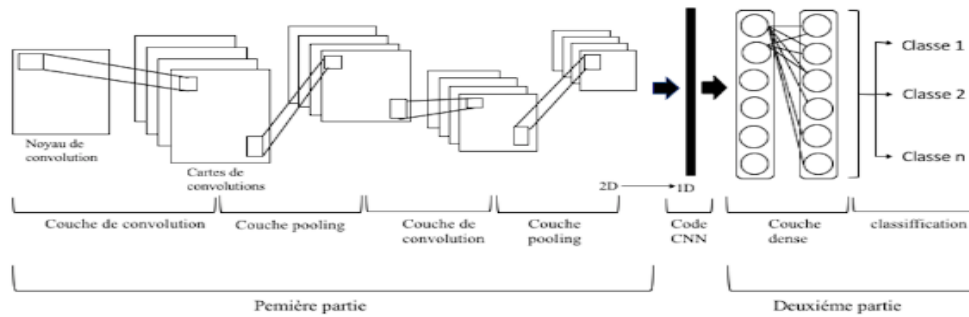


Figure III.11 : Architecture de CNN

La première partie est constituée d’une répétition des opérations de convolution et de pooling comme le montre la figure III.11. Quant à la deuxième partie qui semble plus simple avec une couche des neurones pour la classification.

**La couche d’entrée :**

Le réseau voit les images à traiter comme une matrice des pixels avec des valeurs différentes selon les couleurs présentes dans l’image.

**La couche de convolution :**

Une couche très importante pour extraire les caractéristiques de l’image avec l’utilisation des filtres Kernels.

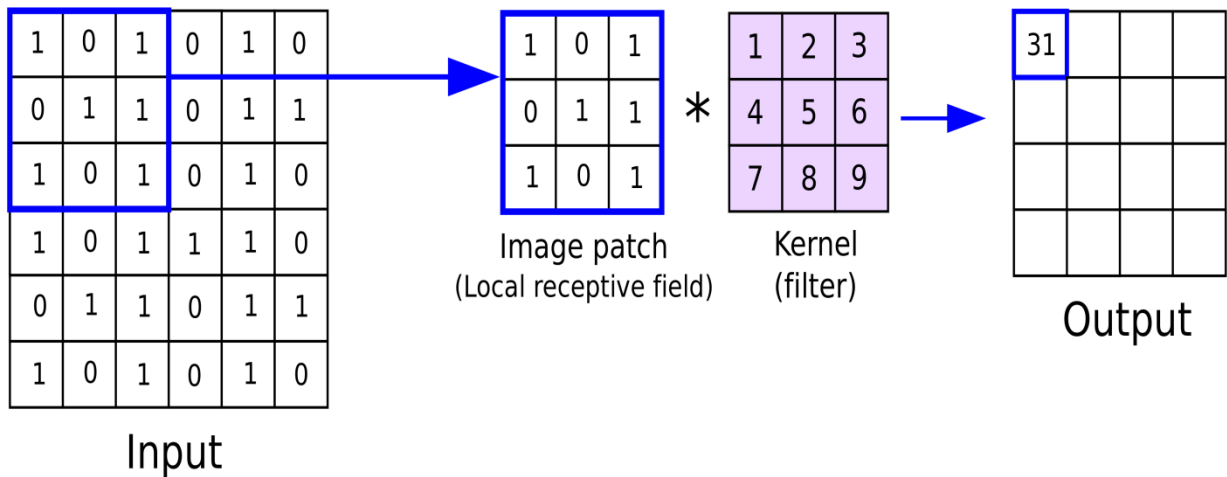


Figure III.12 : Couche de convolution

Cette couche de convolution s’écrit par la formule suivante :

$$W_{out} = \frac{W+F+2P}{s} + 1 \tag{III.7}$$

Avec :

W : C'est la taille de l'image, 28x28 par exemple,  $W = 28$ .

F : La taille de filtre Kernel.

P : Le padding.

S : Le pas de l'utilisation de filtre sur l'image.

Et avec chaque passage par la couche de convolution, la fonction Relu est également utilisée.

### La couche de Pooling :

Les couches de pooling sont utilisées pour essayer de réduire les dimensions afin de traiter rapidement les données et de réduire la complexité.

Il existe deux types de Pooling, Le Max Pooling qui prend les plus grandes valeurs seulement. Et l'Average Pooling qui calcule la moyenne des valeurs.




Figure III.13 : Couche de Pooling

La couche de Pooling se définit par la formule suivante :

$$W_{out} = \frac{W-F}{s} + 1 \quad (III.8)$$

A la fin de cette première partie, les résultats seront mis sur un vecteur 1D qui contient toutes les caractéristiques extraite, ce vecteur s'appelle le CODE CNN.

Ensuite on passe à la deuxième partie qui prend le CODE CNN et qui le passe par la couche entièrement connectée des neurones (Perceptron Multicouche) pour combiner les caractéristiques afin de classer l'image.



### III.5.7.4. Auto-encodeurs (AE) :

Des simples réseaux de neurones qui suivent la méthode d'apprentissage non supervisé avec un objectif de compresser les données d'entrée et puis les reproduire à partir des caractéristiques obtenu lors de la compression.

Les auto-encodeurs se composent de deux parties comme le montre la figure III.14.

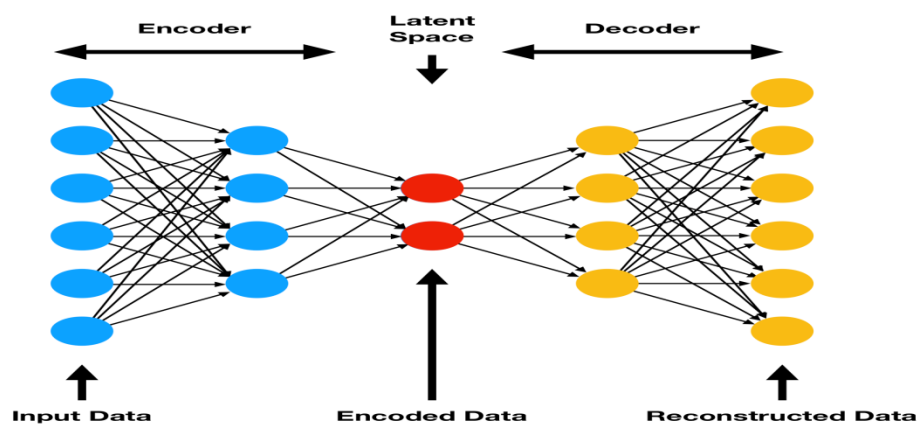


Figure III.14 : Architecture d'un Auto-encodeurs

La partie **Encodeur** : des couches des réseaux neurones avec une tâche de compression et de redimensionnement des données, à la sortie on obtiendra des représentations encodées envoyé vers l'espace latent.

La partie **Décodeur** : Le travail de ces couches c'est l'inverse des encodeurs, en essayant de décompresser les données de l'espace latent et de les reproduire d'une façon qu'elles soient identiques ou presque aux données originales d'entrée.

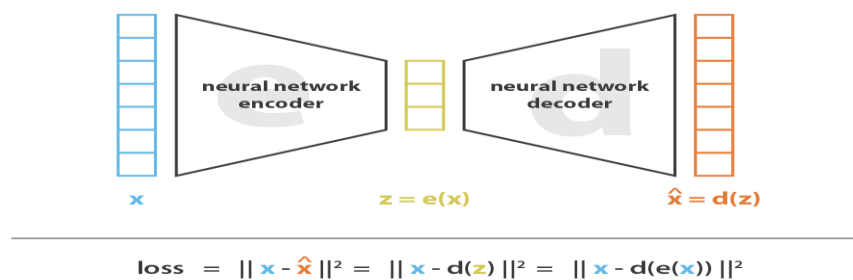
La tâche principale des auto-encodeurs est alors d'essayer de trouver la meilleure représentation possible des données d'entrée.

**III.5.7.4.1 Principe de fonctionnement des auto-encodeurs :**

L'idée est simplement de prendre les données d'entrée  $X$  et leurs donner une nouvelle représentation compressée dite encodée  $E(X)$ . Ces données alors encodée seront envoyées vers l'espace latent  $Z$  pour être utilisées ensuite par la partie décodeur  $D$  qui va essayer à son tour de décompresser ces données  $D(Z)$  et avoir en sortie  $\hat{X}$ .

La fonction cout(Loss) permet de calculer la différence entre les données d'entrée et les données obtenues par le réseau.

$$Loss = \|X - \hat{X}\|^2 \quad (III.9)$$



**Figure III.15 :** Représentation partie encodeur/décodeur

**III.5.7.4.2.Types des auto-encodeurs :**

- Denosing Autoencoders
- Variational Autoencoders
- Sparse Autoencoders

**III.5.8.Types des réseaux neurones :**

Selon les fonctionnalités et les tâches à faire, des différents modèles de réseaux de neurones artificiels existent, chacun avec sa propre architecture et ses propres caractéristiques.

La figure III.16 montre différents modèles des réseaux neurones connus.

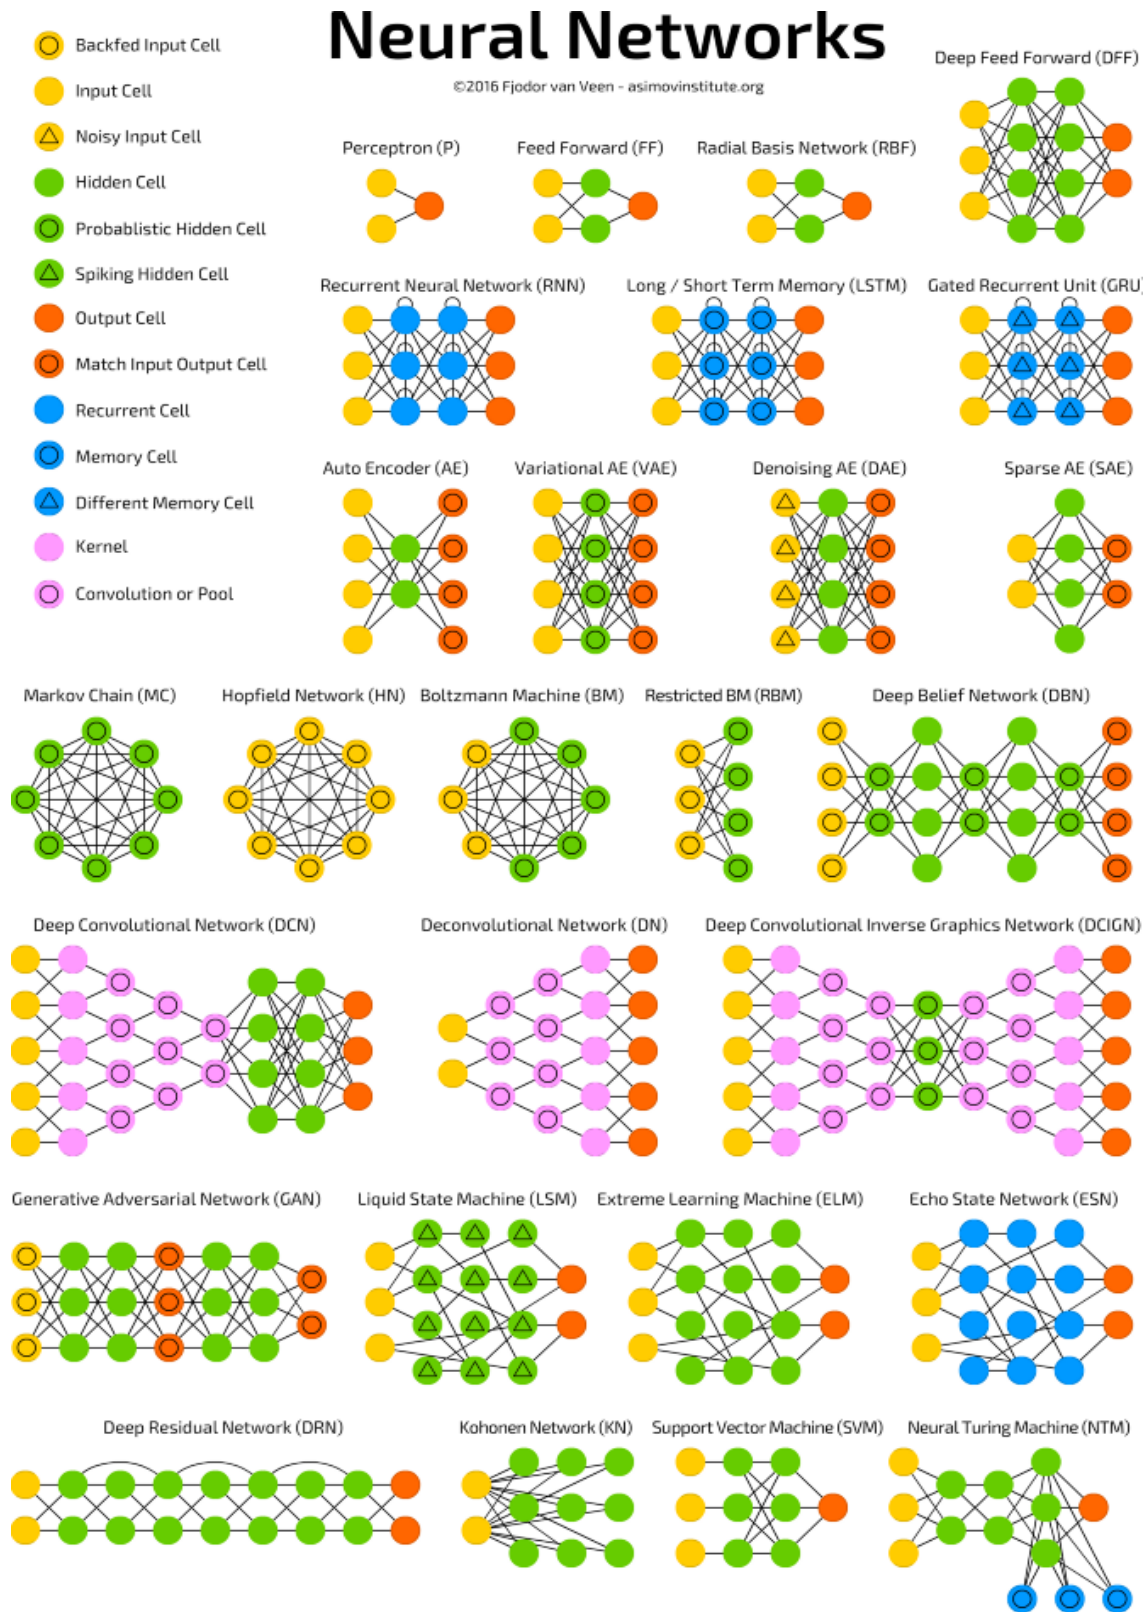


Figure III.16 : Types des réseaux neurones [40].

Afin d’expliquer brièvement chaque type de réseau de neurone artificiel présent dans la figure, on définit par la suite ces modèles :

**Perceptron** : Le premier réseau de neurone et le plus simple entre eux.

**Feed-Forward (FF)** : L'approche de ces réseaux revient au années 50 avec une couche d'entrée et une couche de sortie et couche cachée entre les deux.

**Radial Basis Network (RBN)** : Même principe des réseaux Feed-Forward avec une base radiale comme fonction d'activation.

**Deep Feed-Forward (DFF)** : Des réseaux Feed-Forward mais avec plus de couches cachées.

**Reccurent Neural Network (RNN)** : Appelé récurrents pour ses cellules récurrentes, utilisées pour les données séquentielles.

**Long/Short Term Memory (LSTM)** : Des réseaux qui utilisent des cellules mémoire pour le traitement des données séquentielles également.

**Gated Reccurent Unit (GRU)** : Des LSTM avec plusieurs déclanchement, les GRU consomment moins de ressources mais donne une efficacité remarquable.

**Auto-Encoder (AE)** : Des réseaux avec une tache de matcher les données de sortie aux données de l'entrée.

**Variational AE (VAE)** : Des auto-encodeurs qui compriment les probabilités au lieu des caractéristiques.

**Denoising AE (DAE)** : Des AE avec des données d'entrées bruitées pour forcer le réseau à apprendre et ne pas s'adapter simplement aux données d'entrée (sur-ajustement).

---

**Sparse AE (SAE)** : Des réseaux AE avec un nombre de cellules cachées supérieur aux couches d'entrée et de sortie.

**Markov Chain (MC)** : Un ancien concept qui se base sur les probabilités, utilisé pour la classification basée sur des probabilités ou comme une machine à états finis.

**Hopfield Network (HN)** : formés sur un ensemble limité d'échantillons afin qu'ils répondent à un échantillon connu avec le même échantillon.

**Boltzmann Machine (BM)** : Similaires aux HN avec des cellules d'entrées et des cellules cachées.

**Restricted Boltzmann Machine (RBM)** : Ressemblent aux BM mais avec restriction.

**Deep Belief Network (DBN)** : Plusieurs Boltzmann Machines entourées de VAE.

**Deep Convolutional Network (DCN/CNN)** : Réseau avec plusieurs couches cachées et des couches de convolution.

**Deconvolutional Network (DN)** : Réseau DCN inversé.

**Deep Convolutional Inverse Graphics Network (DCIGN)** : Ressemble à un DCN et DN connecté entre eux, mais ont également la forme d'un AE.

**Generative Adversarial Network (GAN)** : GAN représente une famille de réseaux doubles, composés d'un générateur et d'un discriminateur. Ils essaient constamment de se duper les uns les autres - le générateur essaie de générer des données et le discriminateur, recevant des exemples de données, essaie de distinguer les données générées des échantillons.

**Liquid State Machine (LSM)** : Des réseaux pas entièrement connectée avec remplacement des fonctions d'activation par des seuils.

---

**Extreme Learning Machine (ELM)** : Des FF moins complexes non entièrement connectée.

**Echo State Network (ESN)** : Un sous type des RNN avec une différente technique.

**Deep Residual Network (DRN)** : Un réseau très profond avec un nombre très important de couches cachées.

**Kohonen Network (KN)** : Un réseau qui utilise la fonction « distance à la cellule ».

**Support Vector Machine (SVM)** : utilisé pour la classification binaire seulement, le réseau peut répondre que par OUI ou NON.

**Neural Turing Machine (NTM)** : peuvent être considéré comme des FF avec cellules mémoires extraites.

La figure représente les modèles les plus connus mais il existe également d'autres modèles et types des réseaux de neurones artificiels.

Pour expliquer chacune des cellules des couches d'entrées et des couches de sorties et les couches cachées, le tableau III.2 montre les différents nœuds et cellules utilisé dans les modèles.

	Backfed input cell	Une cellule qui se réalimente avec une autre cellule
	Input cell	Cellule d'entrée
	Noisy input cell	Cellule d'entrée bruitée
	Hidden cell	Cellule cachée
	Probabilistic hidden cell	Cellule cachée qui utilise les probabilités
	Spike hidden cell	L'énergie sortie par la cellule crée un genre de spike
	Output cell	Cellule de sortie
	Match input output cell	Cellule où l'entrée et la sortie doivent avoir les mêmes valeurs
	Recurrent cell	Cellule récurrente qui se retourne toujours vers les données précédentes
	Memory cell	Une cellule qui se dispose d'une mémoire
	Different memory cell	Chaque cellule se dispose de sa propre mémoire
	Kernel	Utilisations des filtres Kernel
	Convolution ou Pooling	Passage par la couche de convolution ou Pooling

Tableau III.2 : différents types de neurones.

### III.5.9.Optimisation des réseaux neurones :

#### III.5.9.1.Fonctions de perte (Loss Functions) :

Afin d'optimiser les NNs avec les différentes méthodes et stratégies pour minimiser l'erreur, le réseau utilise les fonctions coût pour mesurer cette différence entre la valeur réelle et les valeurs prédites par l'algorithme. Ces fonctions coût donnent une idée sur les performances de réseau.

Peuvent être classés en trois types.

**Fonctions de perte de Régression :** A utiliser lorsque le réseau à des valeurs continues à prédire.

Dont on à :

- Erreur quadratique moyenne (Mean squared error (MSE))
- Erreur absolue moyenne (Mean Absolute Error (MAE))
- Erreur logarithmique quadratique moyenne (Mean Squared Logarithmic Error (MSLE))

**Fonctions de perte de classification binaire :** utile quand l'algorithme fait face à une problématique où y a que deux choix comme solution, 0 ou 1, oui ou non, vrai ou faux...

Dont on à :

- Entropie croisée binaire (Binary Cross Entropy)
- Hinge (Hinge Loss)

**Fonctions de perte de classification multi-classes :** A utiliser quand l'algorithme a trois classes ou plus pour ses résultats prédits.

Il y a :

- Entropie croisée catégorielle (Categorical Cross Entropy)
- Divergence de Kullback Leibler (Kullback Leibler Divergence)

Le tableau III.3 montre les formules de ces fonctions [41].



Type	La fonction	La formule	
Régression	Erreur quadratique moyenne	$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$ <p style="text-align: right;">(III.10)</p>	<p>Avec,</p> <p>n : nombre d'observation</p> <p><math>Y_i</math> : valeur réelle</p> <p><math>\hat{Y}_i</math> : valeur à prédire</p>
	Erreur Absolue moyenne	$MAE = \frac{\sum_{i=1}^n  Y - \hat{Y}_i }{n}$ <p style="text-align: right;">(III.11)</p>	
	Erreur logarithmique quadratique moyenne	$MSLE = \frac{1}{n} \sum_{i=1}^n (\log(Y_i) - \log(\hat{Y}_i))^2$ <p style="text-align: right;">(III.12)</p>	
Classification Binaire	Entropie croisée binaire	$LOSS = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)$ <p style="text-align: right;">(III.13)</p>	
	Hinge	$LOSS = \sum_{i=0}^n (\max(0, 1 - y_i \cdot \hat{y}_i)^2)$ <p style="text-align: right;">(III.14)</p>	
Classification Multi-classes	Entropie croisée catégorielle	$LOSS = -\sum_{i=1}^n y_i \log(\hat{y}_i)$ <p style="text-align: right;">(III.15)</p>	<p>P : représente les données, ou une distribution de probabilité</p> <p>Q : une approximation de P.</p>
	Divergence de Kullback Leibler	<p>Pour des distributions discrètes P et Q :</p> $D_{KL}(P  Q) = \sum_i P(i) \log \frac{P(i)}{Q(i)}$ <p style="text-align: right;">(III.16)</p> <p>Pour des distributions continues P et Q :</p> $D_{KL}(P  Q) = \int_{-\infty}^{+\infty} p(x) \log \frac{p(x)}{q(x)} dx$ <p style="text-align: right;">(III.17)</p>	

**Tableau III.3** : Les formules des fonctions de perte.

**III.5.9.2. Complexité des réseaux neurones :**

En regardant les architectures des réseaux neurones on peut clairement assumer que ces algorithmes travaillent d'une manière complexe et difficile à comprendre.

A l'aide de quelques techniques et modification on pourra simplifier le réseau.

**Choix des paramètres :**

- Nombre de couches cachées.
- Nombre de neurones.
- Compression ou suppression des données non utiles à l'entrée.
- Taux d'apprentissage.
- Nombre d'epochs.

Mais en modifiant ces paramètres, ça risque d'influencer les performances de l'algorithme et on obtiendra une efficacité moins bonne. C'est l'inconvénient de cette technique.

**Régularisation :**

C'est une méthode qui implique une introduction d'un terme de régularisation ou de pénalisation dans l'objectif d'optimiser l'algorithme, et réduire la possibilité d'un sur-apprentissage également. Le principe de cette technique est alors de diminuer les valeurs des poids importants (weight decay) pour que le modèle ne se concentre pas sur quelques données mais sur toutes les données.

Parmi les méthodes de régularisation, il existe :


- L1 régularisation : L'ajout d'un terme (la valeur absolue des poids) à la fonction de perte.
- L2 régularisation : L'ajout d'un terme (le carré des poids) à la fonction de perte.
- DropOut : Ignorer un certain nombre de neurones choisi au hasard.
- Early stopping : L'arrêt de l'entraînement quand il arrive à un niveau suffisant de performance.

**III.5.9.3. Rétro-propagation (Back-propagation):**

Dans les réseaux neurones artificiels le passage de l'entrée du réseau à la sortie s'appelle le chemin direct (Feed-forward), mais afin d'avoir un modèle qui assure des bonnes performances la rétro-propagation (Back-propagation) est présente pour faire le chemin inverse.

L'idée est alors de faire le chemin inverse avec le calcul de gradient à partir de la couche de sortie par rapport à la dernière couche qui procède jusqu'à arrivé à la première couche et de mettre à jour les poids et les biais à chaque itération à ce qu'on arrive à des valeurs de poids et biais parfaite pour l'algorithme pour l'entraîner.

La figure III.17 montre une illustration de la rétro-propagation.



**Figure III.17 :** La rétro-propagation.

**III.6. Conclusion :**

Au cours de ce chapitre, on a présenté brièvement les réseaux neurones et l'apprentissage automatique avec ses types, ses applications, ses différents algorithmes. Ensuite on a expliqué le principe de l'apprentissage profond, ainsi qu'un bref historique, ses différents modèles et ses avantages. En terminant ce chapitre on a une idée générale de ce que proposent ces technologies et techniques.

Nous allons simuler dans le chapitre suivant les deux techniques de la partie théorique, la modulation OFDM et la technique OFDM-AE.

**CHAPITRE IV**  
**IMPLEMENTATION D'UN OFDM A**  
**BASE D'AUTO-ENCODEUR**

---

### IV.1.Introduction :

Ce chapitre IV va se concentrer sur l'implémentation d'un réseau de neurones comme l'Auto-Encodeur qui fait la modulation OFDM et d'un système classique de la technique de modulation OFDM.

Le chapitre se divise en deux parties, une première partie qui présente le système de modulation classique et ses blocs avec les résultats obtenus, et la deuxième partie expose la technique de modulation OFDM en utilisant les auto-encodeurs avec les résultats obtenus.

### IV.2.Environnement et outils :

Cette partie donne une simple présentation des langages et plateformes utilisées pour réaliser la tâche voulue, qui permet de faire l'implémentation de modèle OFDM à base des réseaux de neurones comme l'Auto-Encodeur et l'OFDM classique.

#### IV.2.1.Environnement de développement :

- **Google Colab** : Une plateforme qui permet d'écrire et d'exécuter un code de son choix. Un service offert par Google gratuitement qui se base sur Jupyter Notebook pour la recherche et la formation dans le domaine de l'apprentissage automatique.

La plateforme présente de nombreux avantages pour améliorer ses compétences en programmation, le développement des applications en apprentissage profond à l'aide des bibliothèques, bénéficie d'accès à un environnement puissant avec un GPU gratuitement et sans configuration.

#### IV.2.2.Langages de programmation :

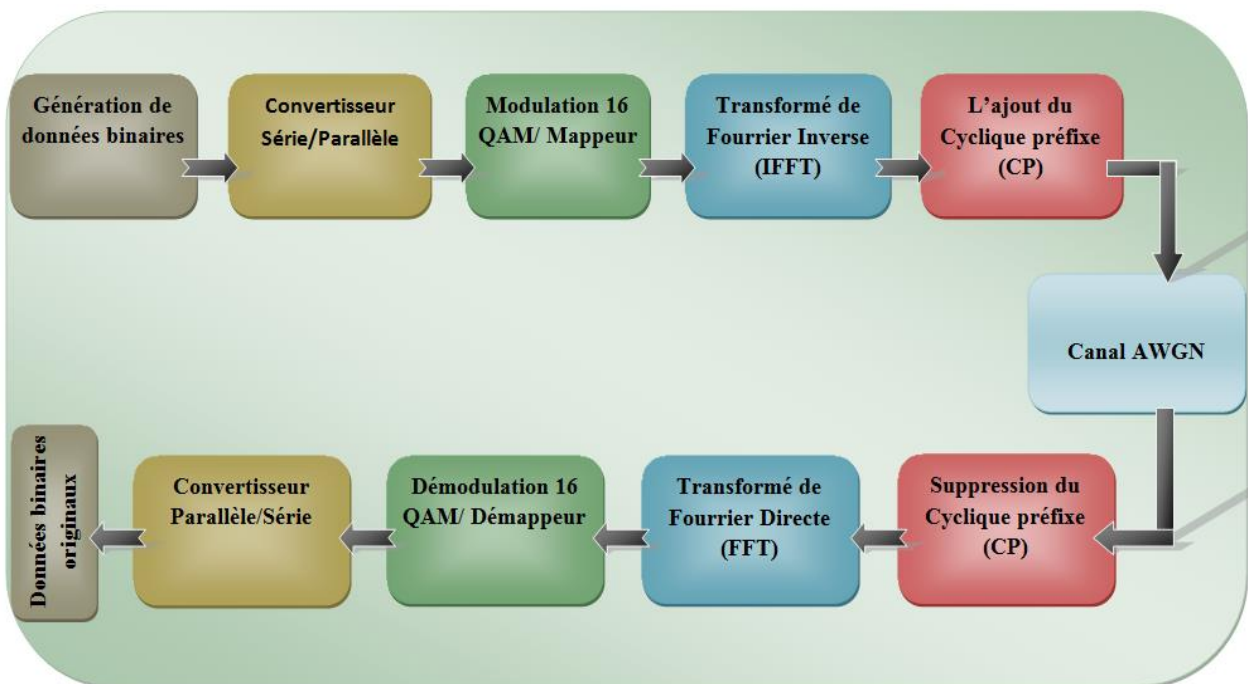
- **Python** : L'un des langages de programmation les plus puissants et les plus utilisés par les développeurs, considéré comme un langage de programmation parfait pour le développement des algorithmes de AI.

**IV.2.3. Bibliothèques utilisées :**

- **Keras** : Une bibliothèque qui permet de définir et implémenter les différentes couches du modèle et d'autres paramètres similaires.
- **Tensorflow** : Une grande bibliothèque qui offre la possibilité de former et d'écrire un réseau de neurones.
- **NumPy** : Une bibliothèque spéciale pour la manipulation des tableaux et matrices et des fonctions mathématiques.
- **Panda** : Un outil de manipulation des données et d'analyse.
- **Matplotlib** : Une bibliothèque présente dans le langage de programmation python, utilisé pour le traçage et la visualisation des données sous forme des graphes...
- **SciPy** : Une bibliothèque de python qui contient une collection des algorithmes mathématiques et des fonctions spéciales comme FFT, signal...

**IV.3. Système OFDM classique :**

Pour voir comment se comporte un système OFDM classique on se sert d'une simulation de cette technologie, dont ses différents blocs sont montrés sur la figure IV.1.



**Figure IV.1** : Schéma des blocs de système OFDM.

Chacun des blocs du système à une tâche spécifique avec des paramètres spécifiques.

**Générateur de données binaires :** Son travail consiste à générer des données de types binaires (1 et 0), où on a décidé de générer dans notre cas une quantité équilibrée entre les 0 et les 1.

**Convertisseur Série Parallèle :** Qui fait la conversion des données en série reçues vers des quantités parallèles selon le nombre de bits par symbole souhaitable.

**Modulation 16QAM/ Mappeur :** La modulation d'amplitude en quadrature qui se fait selon un dictionnaire de codage de Grey où chaque symbole correspond à sa valeur complexe.

**Transformée de Fourier Inverse :** Sert à faire le passage du domaine fréquentiel au domaine temporel en gardant la même taille du signal.

**Cyclique Préfixe :** Une quantité de données qui s'ajoute au signal pour limiter les interférences entre symboles, le nombre de CP peut être variable comme 25% du bloc, 12,5%, ... ou peut être nul.

**Canal AWGN :** Là où on génère un bruit additif blanc, qui s'influence avec la valeur du SNR qui va de 0dB à 25dB/30dB.

**Transformée de Fourier Directe :** Qui fait l'inverse de l'IFFT, le passage du domaine temporel vers le domaine fréquentiel.

**Démodulation 16QAM/Démappeur :** Le passage de la forme complexe aux symboles selon le dictionnaire de modulation.

**Convertisseur Parallèle Série :** Redimensionnement des données parallèles en série pour enfin les comparer avec les données d'entrée.

**IV.4.Simulation OFDM classique :****IV.4.1.Paramètres utilisées :**

Les paramètres utilisés dans notre simulation sont présentés dans le tableau IV.1.

Nombre de sous-porteuse	64
Cyclique préfixe	0
Type de modulation	16 QAM (N = 4)
Bits par symbole	4
Codage de Grey	De « -3-3j » à « +3+3j »
SNR	De 0dB à 25dB

Tableau IV.1 : Paramètres de simulation d'OFDM classique.

**IV.4.2.Résultats :**

On va montrer et discuter les résultats obtenus lors de la simulation du système OFDM classique.




Figure IV.2 : Constellation 16QAM.



La figure IV.2 montre la constellation 16QAM qui permet de voir les emplacements des symboles possibles obtenus avec le codage de Grey.




Figure IV.3 : Signal émetteur et récepteur.

Les deux signaux représentés sur la figure IV.3 sont pour le signal avant le passage par le canal AWGN qui est en bleu, et le deuxième signal en orange après le passage par le canal AWGN.






Figure IV.4 : Constellations reçues.

Les constellations de la figure IV.4 montrent l'emplacement des séquences reçus.



**Figure IV.5 :** Densité spectrale de puissance de l'OFDM classique.



**Figure IV.6 :** Taux d'erreur binaire (BER) de l'OFDM classique.

IV.5.Système OFDM-AE :

Le modèle que nous présentons est composé de onze couches qui se compose d'une couche d'entrée et une couche de sortie, cinq couches cachées dont trois couches cachées pour la partie **encodeur** et deux pour la partie **décodeur**. Et entre les deux parties de l'AE on a une couche de normalisation et trois couches pour le système OFDM, comme le montre la figure IV.7.

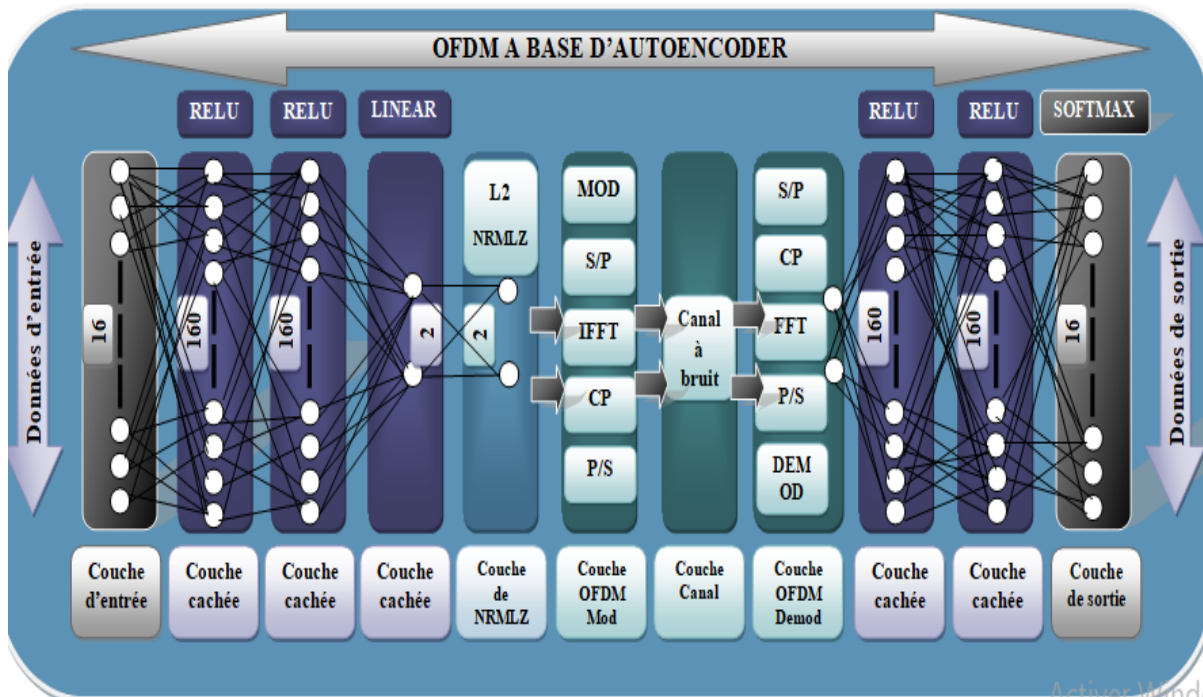


Figure IV.7 : Architecture du système OFDM-AE.

Chaque couche est différente de l'autre en termes de nombre de neurones, la tâche...

**Couche d'entrée :** La première couche qui reçoit les données pour les faire passer à travers ces neurones vers les couches suivantes, la couche d'entrée utilisée pour notre simulation est constituée de 16 neurones.

**Couche cachée 1 :** Cette couche est configurée avec 160 neurones avec une fonction d'activation ReLu.

**Couche cachée 2 :** La deuxième couche cachée est identique à la couche précédente avec le même nombre de neurones et la même fonction d'activation.

**Couche cachée 3 :** Pour arriver à l'espace latent, cette couche utilise seulement deux neurones pour provoquer l'AE à faire la compression des données qui est l'une de ses tâches principales.

**Couche de normalisation :** Une couche utile pour le modèle qui fait accélérer et stabiliser le processus de l'apprentissage de l'algorithme.

**Couche de modulation OFDM :** Cette couche est basée sur une fonction de modulation OFDM en passant par ses blocs tels que le S/P, IFFT...

**Couche de canal à bruit :** Un canal AWGN qui fait l'ajout du bruit au signal reçu.

**Couche de démodulation OFDM :** S'intéresse à faire la démodulation du signal après le passage par le canal en utilisant les différentes opérations (S/P, FFT, Démodulation...)

**Couche cachée 4 :** Après la démodulation du signal et pour donner le pouvoir à l'AE à reproduire les données compressées, cette couche est constituée de 160 neurones avec ReLU comme fonction d'activation.

**Couche cachée 5 :** Couche identique à la couche cachée quatre avec 160 neurones et la fonction d'activation ReLU.

**Couche de sortie :** Enfin pour avoir les mêmes résultats que les données d'entrée, cette couche est formée de 16 neurones comme la couche d'entrée avec la fonction d'activation Softmax.

Afin d'avoir de bons résultats et permettre à l'AE de s'entraîner dans les meilleures conditions, il faut bien optimiser le modèle, pour cela on utilise le « Adamax Optimizer » qui est un algorithme d'optimisation qui aide à donner une meilleure performance au modèle. On ajoute la « Categorical Cross Entropy » également qui fait les calculs de différence entre les données d'entrée et les données prédites (LOSS).

Les détails des couches et la configuration du modèle est affiché par `name.summary()` pour avoir comme résultats la figure IV.8.

```

Model: "AE_OFDM"
-----
Layer (type)                Output Shape                Param #
-----
input_3 (InputLayer)        [(None, 16)]                0
dense_5 (Dense)              (None, 160)                 2720
dense_6 (Dense)              (None, 160)                 25760
dense_7 (Dense)              (None, 2)                   322
lambda_3 (Lambda)           (None, 2)                   0
lambda_4 (Lambda)           (1, 1024000)                0
canal_AWGN (Lambda)         (1, 1024000)                0
lambda_5 (Lambda)           (1024000, 2)                0
dense_8 (Dense)              (1024000, 160)              480
dense_9 (Dense)              (1024000, 160)              25760
Sortie_globale (Dense)      (1024000, 16)               2576
-----
Total params: 57,618
Trainable params: 57,618
Non-trainable params: 0

```

**Figure IV.8** : Configuration de l'OFDM-AE.

La première colonne à gauche montre les différentes couches du modèle, la colonne au milieu est pour la taille de sortie de chaque couche et le nombre de neurone, et la dernière colonne est utile pour voir le nombre de paramètres utilisés par le modèle pour l'entraînement de chaque couche.

**IV.6.Simulation système OFDM-AE :****IV.6.1.Paramètres utilisés :**

Les paramètres utilisés lors de la simulation OFDM-AE sont montrés sur le tableau IV.2.

Nombre de sous porteuses	64
Cyclique préfixe	0
Type de modulation	16 QAM (N = 4)
SNR	0dB à 20dB
Nombre d'Epoch	350
Flux de données pour la phase d'apprentissage	1024000
Flux de données pour la phase de généralisation	192000

Tableau IV.2 : Paramètres de simulation d'OFDM-AE.

**IV.6.2.Résultats :**

Après la phase d'entraînement de l'AE et son optimisation on obtient les résultats suivants.





Figure IV.9 : Courbe de Loss d'OFDM-AE.




**Figure IV.10 :** Courbe d'accuracy d'OFDM-AE.

Pour savoir si le modèle fonctionne bien et fournit de bons résultats, il faut regarder les courbes d'accuracy et de Loss. Les courbes de Loss et accuracy sont les résultats d'entraînement, et les courbes de validation Loss et accuracy sont pour la phase de généralisation.


Plus les valeurs de Loss tendent vers le zéro plus notre modèle est bon, plus les valeurs de l'accuracy se rapprochent de la valeur 1, plus le modèle fournit de bon résultat.

Les figures IV.9 et IV.10 montrent les résultats.

La figure IV.11 montre les constellations de l'OFDM-AE de type 16 QAM.




**Figure IV.11** : Constellation d'OFDM-AE.



**Figure IV.12** : Densité spectrale de puissance d'OFDM-AE.


La densité spectrale de puissance est le module carré de la transformée de Fourier du signal, elle permet de décrire la puissance du signal en fonction de la fréquence, comme le montre la figure IV.12.





**Figure IV.13 :** Taux d'erreur binaire (BER) d'OFDM-AE.

La figure IV.13 montre le graphe de taux d'erreur binaire de ce système OFDM à base d'AE. Qui représente le nombre erronés des bits reçus sur le nombre total émis, en fonction du SNR.



**Figure IV.14 :** DSP d'OFDM classique/ DSP d'OFDM-AE.

#### IV.7.Conclusion :

A la fin de ce chapitre et d'après les résultats obtenus des simulations on constate que les réseaux neurones peuvent être utilisés pour la technique de modulation OFDM pour les prochaines générations mobiles et pour les réseaux sans fils en générale malgré la complexité de ces réseaux de neurones artificiels.

# **CONCLUSION GENERALE**

L'évolution rapide des technologies des réseaux mobiles cellulaire et des communications numériques sans fil exige aux constructeurs et les impose à trouver des alternatives pour les techniques des systèmes de communications tel que la technique de modulation OFDM afin d'optimiser ces réseaux en terme de performance et d'énergie des signaux. Pour cela l'intelligence artificielle peut contribuer à ce processus d'optimisation en utilisant les réseaux de neurones artificiels.

Le principal objectif de ce projet est de voir la réaction de l'intégration des réseaux de neurones artificiels avec les techniques de communication numérique et le fonctionnement de ces systèmes.

La simulation sous Python de la technique de modulation OFDM classique qu'on à réalisé a permis d'appliquer les notions dont on à parlé lors du deuxième chapitre et nous à permis de voir les différents résultats des différents étapes que utilise cette méthode.

La deuxième simulation de l'OFDM à base d'AE qu'on à étudié les techniques des réseaux de neurones artificiels sur les systèmes numériques avec les résultats obtenus à donné le moyen de rendre possible et d'encourager l'émergence des technologies de l'AI dans les réseaux cellulaire. Les résultats obtenus lors de l'utilisation de la technique OFDM-AE montrent une efficacité qui peut être considéré comme satisfaisante en comparant des méthodes similaires.

Nous espérons dans des futurs travaux pouvoir élargir et fondé profondément notre étude sur l'utilisation des réseaux neurones et l'apprentissage profond dans les télécommunications en général et en se concentrant sur les communications sans fil, afin d'arriver peut être à des résultats bien meilleurs en développons encore mieux le système.

Plusieurs études sur l'utilisation de l'apprentissage profond dans les réseaux cellulaires futurs comme la 6G sont en cours. Cette émergence ouvrira une nouvelle porte sur le développement des communications numériques.

# Bibliographie

- [1] J. R. Barry, E. A. Lee, et D. G. Messerschmitt, Digital Communication. Springer Science & Business Media, 2012.
- [2] Introduction aux communications numériques. Cours et exercices corrigés 2e édition - Michel Joindot, Alain Glavieux.
- [3] P. Prandoni et M. Vetterli, Signal processing for communications. Lausanne (Suisse) Boca Raton (États-Unis): EPFL Press CRC Press, 2008.
- [4] J. Proakis et M. Salehi, Digital Communications, 5e édition. Boston: McGraw-Hill Higher Education, 2007.
- [5] H. Sari, «Transmission des signaux numériques », Techniques de l'Ingénieur. 10 juin 1995.
- [6] F. Launay « Le réseau 5G – 5GS | Frédéric Launay », 24 août 2018, [blogs.univ-poitiers.fr/f-launay/2018/08/24/le-reseau-5g-5gs/](https://blogs.univ-poitiers.fr/f-launay/2018/08/24/le-reseau-5g-5gs/).
- [7] « LES ENJEUX DE LA 5G », Autorité de régulation des communications électroniques et des postes, Mars 2017.  
[www.arcep.fr/uploads/tx\\_gspublication/rapport-enjeux-5G\\_mars2017.pdf](http://www.arcep.fr/uploads/tx_gspublication/rapport-enjeux-5G_mars2017.pdf)
- [8] C. Watson, K. Woods, et D. Shyy, « TW: 6G and Artificial Intelligence & Machine Learning »
- [9] M. Giordani, M. Polese, M. Mezzavilla, S. Rangan, et M. Zorzi, « Towards 6G Networks: Use Cases and Technologies ». arXiv, 4 février 2020.
- [10] M. Z. Zaaimia, M. C. B. Hadji, et M. S. Haddad, « Etude des techniques de modulation pour les réseaux mobiles 5G et 6G de nouvelle génération. »
- [11] X. Lagrange « Principe de la transmission OFDM - Utilisation dans les systèmes cellulaires », technique de l'ingénieur, 10 Mai 2012.
- [12] H. Schulze et C. Lueders, Theory and Applications of OFDM and CDMA: Wideband Wireless Communications. John Wiley & Sons, 2005.
- [13] « Orthogonal frequency-division multiplexing », Wikipédia. 16 février 2022.
- [14] L. Hanzo, « for Broadband Multi-user Communications, WLANs and Broadcasting »
- [15] « G.A. Franco and G. Lachs, « An orthogonal coding technique for Communications », IRE Intern. »
- [16] Virginie Dégardin, " Analyse de la faisabilité d'une transmission de données haut débit sur le réseau électrique basse tension. ", Doctorat, université de Lille 1, 2002
- [17] HO Anh Tai « Application des techniques multiporteuses de type OFDM pour les futurs systèmes de télécommunications par satellite », Doctorat, université de Toulouse, 30 Mars 2009.
- [18] P. H. Moose, « A technique for orthogonal frequency division multiplexing frequency offset correction », IEEE Transactions on Communications, vol. 42, n° 10
- [19] H. B. Hnia, A. Kachouri, O. B. Belghith, et L. Kamoun, « Etude des performances de la modulation OFDM pour l'utilisation dans les systèmes de communication sans fils de la 4G », p. 5.
- [20] Daoud khedidja " SIMULATION COMPARATIVE DES TECHNIQUES FBMC ET OFDM POUR LES RESEAUX 5G", Master, université de Tlemcen, 2016

- [21] Y. Abdessamad, M.Ibrahim « Les différentes formes d'ondes candidates dans les applications 5G », Master, 2019 Université 8Mai 1945 – Guelma.
- [22] H.Ait.Taleb « UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE MIMO-OFDM POUR LES COMMUNICATIONS SANS-FIL DANS LES MINES SOUTERRAINES » Maitrise, Université de Québec, 2017.
- [23] Y. Abdessamad, M.Ibrahim « Les différentes formes d'ondes candidates dans les applications 5G », Master, 2019 Université 8Mai 1945 – Guelma.
- [24] H.Ait.Taleb « UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE MIMO-OFDM POUR LES COMMUNICATIONS SANS-FIL DANS LES MINES SOUTERRAINES » Maitrise, université de Québec, 2017.
- [25] N. Michailow et al., « Generalized Frequency Division Multiplexing for 5th Generation Cellular Networks », IEEE Trans. Commun., vol. 62, n° 9, p. 3045-3061, sept. 2014, doi: 10.1109/TCOMM.2014.2345566.
- [26] D. Pastre, Module « INTELLIGENCE ARTIFICIELLE DEFINITION - GENERALITES - HISTORIQUE - DOMAINES », Université Paris 5, 1999/2000.
- [27] « Qu'est-ce que le Machine Learning ou apprentissage automatique ? », Intelligence artificielle & Data Analytics.
- [28] L. Bastien, « Machine Learning : Définition, fonctionnement, utilisations », Formation Data Science | DataScientest.com, 18 novembre 2020.
- [29] M. Hossam, « Deep Learning ou Apprentissage Profond : qu'est-ce que c'est ? », Formation Data Science | DataScientest.com, 28 septembre 2020.
- [30] « Neural Networks - Biology ». <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/Biology/index.html>
- [31] O. Ezratty, « Les usages de l'intelligence artificielle », p. 742.
- [32] H. Wang et B. Raj, « On the Origin of Deep Learning ». arXiv, 2 mars 2017.
- [33] D. Ramos, « Real-Life Applications of Neural Networks | Smartsheet », 19 juillet 2021.
- [34] « Weights and Biases | AI wiki ». <https://machine-learning.paperspace.com/wiki/weights-and-biases>
- [35] Sibانjan Das, Umit Mert Cakmak, « The sigmoid function - Hands-On Automated Machine Learning [Book] », Avril 2018.
- [36] Antonio Gulli, Sujit Pal, « Activation function — ReLU - Deep Learning with Keras [Book] », Avril 2017.
- [37] K. Pawar, « SoftMax Activation Function | InsideAIML », 2021.
- [38] « What is Perceptron: A Beginners Guide for Perceptron », Simplilearn.com, 20 juin 2022.
- [39] K. O'Shea et R. Nash, « An Introduction to Convolutional Neural Networks ». arXiv, 2 décembre 2015.
- [40] A. Tch, « The mostly complete chart of Neural Networks, explained », Medium,
- [41] « Loss functions | Build an AI model | Peltarion Platform », Peltarion. <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions>