



République Algérienne Démocratique Et Populaire
Ministère de l'Enseignement Supérieur
Et de la Recherche Scientifique



Université Kasdi Merbah Ouargla

Faculté des Nouvelles Technologies de l'Information et de la Communication

Département d'Electronique et Des Télécommunications

Mémoire de Fin d'Étude

En vue de l'obtention du diplôme de

MASTER ACADEMIQUE

Domaine : Sciences et Technologie

Filière : Télécommunication

Spécialité : Systèmes de Télécommunication

Thème

**Emploi de la Technique Deep Learning dans
Les Systèmes Mobiles 5G à Onde Millimétrique**

Réalisé par :

- BOUMAZA Amel
- MOGDAD Yamina

Soutenu en October 2020 devant le jury composé de :

Mr. CHEBARA Fouad	M.C.A	Président	UKM Ouargla
Mr. MOAD Mouhamed Esayeh	M.A.A	Examineur	UKM Ouargla
Mr. AOUNALLAH Naceur	M.C.B	Encadreur	UKM Ouargla

Année Universitaire : 2020/2021

بِسْمِ اللّٰهِ الرَّحْمٰنِ الرَّحِیْمِ

Remerciements

Tout d'abord, merci et louange à Dieu Tout-Puissant de nous avoir accordé le courage, la volonté et la patience de faire ce travail actuel, et nous remercions nos chers parents qui nous ont soutenus tout au long de notre parcours académique.

Ce travail a été réalisé sous la direction du professeur Aoun Allah Naceur, à qui nous tenons à exprimer notre gratitude pour ce qu'il nous a fourni.

Nous remercions notre famille, Boumaza et Mogdad, pour leur assistance morale et matérielle tout au long de la période de préparation.

Nous tenons également à remercier tous les enseignants qui ont contribué à notre formation au Département des Télécommunications.

Nous remercions les jury :CHEBARA Fouad et MOAD Mouhamed d'avoir accepté la lecture et l'évaluation de ce modeste ouvrage, et enfin nous adressons nos plus vifs remerciements à tous ceux qui nous ont aidés directement ou indirectement à rédiger cette modeste thèse.

Dédicaces

إلى تلك التي أوصاني بها ربي الى تلك التي أعلم أنها تحبني كثيرا إلى عطري المفضل أمي الجميلة
إلى صاحب القلب الطيب سيدي و بطلي أبي الرائع حفظكم الله وبارك فيكما وجعلكما تاجا فوق
رأسي

إلى الغالية الحنون جدتي أمة حفظك الله وأطال الله في عمرك وبارك الله لنا فيكي يارب
إلى روح قلبي جدي حسن طيب الله ثراه وجدي عبد الرحمان رحمها الله وأسكنها فسيح جناته
إلى المنار نصف القلب أخي أحمد

إلى توأم روحي وذراعي الأيمن سالي و بلقيس

إلى اختي الكبرى رفيدة

إلى خالتي الرائعة التي أحبا كثيرا رحمة و أبناءها أنور و رواسي

إلى أعز أخوالي عبد الحلیم وخالتي العید والعزیزة طاطا نعمة وكل عائلتي فردا فردا

إلى صديقاتي الوفيات وبالأخص يمينة ياسمين منال بريزة وإلى كل صديقاتي الغاليات إلى كل
زملائي و زميلاتي في الدراسة

إلى جميع أساتذتي الكرام من أول مشواري الدراسي إلى آخر لحظة

إلى كل روح أحببني بصدق و شاركتني في دعائها

حفظكم الله جميعا

بومعزة آمال

Dédicaces

إلى من لا يمكن للكلمات أن توفي حقهما، إلى من لا يمكن للأرقام أن تحصي
والداي الغاليين أدامهما الله لي فضائلاهما إلى
إلى الوجه الذي لا يكف ابتساما، إلى من سعى وشقى لأنعم بالراحة والهناء الذي لم
يبخل بشيء من أجل دفعي في طريق النجاح الذي علمني ان ارتقي سلم الحياة بحكمة
وصبر
أبي العزيز
إلى ملاكي في الحياة، إلى معنى الحب والحنان، إلى بسمة الحياة وسر الوجود
إلى من كان دعائها سر نجاحي وحنانها بلسم جراحي إلى أعلى الحبايب
أمي الحبيبة
إلى من حبهم يجري في عروقي أشقاء روعي أخواتي جميلة، اسماء، نورة،
وأخي الغالي عبد الحميد
إلى ابناء اختي اميرة ونجاح
إلى أخواتي التي لم تلهن أمي، إلى من سعدت برفقتهم في دروب الحياة وتشاركنا
مرارة وحلاوة الحياة
إلى من كانوا معي على طريق النجاح والخير صديقاتي وبالأخص امال ،ياسمين ،
منال،، وزميلي العيد
إلى جميع أحبتي إلى أعز الأحباب والأصدقاء، إلى كل من ساعدني من قريب أو بعيد
إلى جميع أساتذتي
إلى جميع زملائي، طلبة دفعة 2020

مقداد يمينة

Résumé

Les progrès dans les systèmes sans fil et le besoin d'accueillir plus d'utilisateurs à des débits de données plus élevés avec une meilleure fiabilité tout en consommant moins d'énergie a imposé la naissance d'une nouvelle génération de communication mobile qui est la 5G. Après le succès récent de deep learning par son intégration dans des nouveaux systèmes puissants qui permet de résoudre plusieurs problèmes, dans cette recherche, nous combinons l'optimisation par intelligence artificielle basant sur la technique du deep learning avec la recherche sur les réseaux mobiles en présentant une étude complète des recoupements entre ces deux domaines. Ces derniers temps, le succès de l'apprentissage en profondeur est soutenu par de nouveaux outils puissants qui abordent les problèmes dans cet espace, car il est devenu évident à travers les exemples fournis avec leurs résultats que l'apprentissage en profondeur peut résoudre de nombreux problèmes avec une grande efficacité tels que l'estimation de canal, l'atténuation expérimentale de la pollution, le codage de source et de canal et la formation de faisceaux. ... etc.

Mots clés : Intelligence artificielle, MIMO massif, 5G, beamforming, Apprentissage profond.

Abstract:

Advances in wireless systems and need to accommodate more users at higher data rates with better reliability while consuming less power has imposed the birth of a new generation of mobile communication which is the 5G. After the recent success of deep learning by its integration into powerful new systems that solve several problems, in this research, we combine the optimization by artificial intelligence based on the technique of deep learning with the research on mobile networks by presenting a complete study of the overlaps between these two areas. In recent times, the success of deep learning is supported by powerful new tools that tackle the issues in this space, as it has become evident through the examples provided with their results that deep learning can solve many problems with high efficiency such as channel estimation, experimental pollution attenuation, source and channel coding and beamforming. ... etc.

Keywords: Artificial intelligence, massive MIMO, 5G, beamforming, Deep learning.

ملخص:

إن التقدم في الأنظمة اللاسلكية والحاجة إلى استيعاب المزيد من المستخدمين بمعدلات بيانات أعلى مع موثوقية أفضل مع استهلاك طاقة أقل فرض ولادة جيل جديد من الاتصالات المتنقلة وهو **5G**. بعد النجاح الأخير للتعلم العميق من خلال اندماجه في أنظمة جديدة قوية تحل العديد من المشكلات ، في هذا البحث ، نجمع بين التحسين بواسطة الذكاء الاصطناعي القائم على تقنية التعلم العميق مع البحث على شبكات المحمول من خلال تقديم دراسة كاملة للتداخل بين هذين المجالين. في الأونة الأخيرة ، يتم دعم نجاح التعلم العميق من خلال أدوات جديدة قوية تعالج القضايا في هذا الفضاء ، حيث أصبح واضحًا من خلال الأمثلة المقدمة مع نتائجها أن التعلم العميق يمكن أن يحل العديد من المشكلات. المشكلات ذات الكفاءة العالية مثل تقدير القناة والتوهين التجريبي للتلوث وتشفير المصدر والقناة وتشكيل الحزمة. ... الخ

الكلمات الرئيسية: الذكاء الاصطناعي ، **MIMO** الهائل ، **5G** ، تشكيل الحزم ، التعلم العميق.

Liste des Figures

Figure I.1: les générations des réseaux mobiles.....	6
Figure I.2 : Classification des cas d'utilisation de la 5G de haut niveau.....	8
Figure I.3 : Technologies 5G.....	9
Figure I.4 : Bande d'ondes millimétriques.....	9
Figure I.5 : Le spectre 5G onde millimétrique.....	10
Figure I.6: Propagation des ondes 5G.....	12
Figure I.7 : Petite cellule (Small cell).....	13
Figure I.8: Illustration de la liaison descendante Massive MIMO en communication en visibilité directe.....	15
Figure I.9: Les régions des possibles (M, K) dans les systèmes TDD et FDD, pour un intervalle de cohérence de 200 symboles.....	16
Figure I.10: Système Massive MIMO en transmission multi-utilisateurs [17].....	18
Figure I.11: Full – duplex.....	18
Figure I.12: Émetteur-récepteur duplex intégral.....	19
Figure I. 13: CloudRAN.....	21
Figure I. 14: Architecture de la 5G.....	22
Figure II.1 : la relation entre deep learning et ML et IA.....	24
Figure II.2. : Méthodes d'apprentissage automatique.....	26
Figure II.3 : Qualité des données.....	27
Figure II.4 : Une comparaison des étapes du fonctionnement des algorithmes DL et ML	28
Figure II.5 : Structure d'un réseau de neurone biologique et le cerveau humain	29
Figure II.6: Une explication simple du travail du réseau neuronal artificiel.....	30
Figure II.7 : Illustration des processus d'apprentissage et d'inférence d'un CNN à 4 couches. $w(.)$ désigne les poids de chaque couche cachée, $\sigma(.)$ est une fonction d'activation, λ désigne le taux d'apprentissage, \otimes désigne l'opération de convolution et $\mathfrak{L}(\cdot)$ est la perte.....	32
Figure II.8 : Une présentation hiérarchique des facteurs qui permettent à l'apprentissage profond d'être largement déployé dans le système de réseau mobile.....	34
Figure III.1: CDF de l'efficacité spectrale descendante et du MSE des efficacités spectrales avec précodages MR et M-MMSE en utilisant le réseau de neurone	

du tableau III.2.....	45
Figure III.2: CDF de l'efficacité spectrale descendante avec précodages MR et M-MMSE en utilisant le réseau de neurone du tableau III.2.....	46
Figure III.3: Architecture DL pour la suppression des brouilleurs.....	48
Figure III.4: L'entrée du tenseur dans le modèle DL.....	49
Figure III.5: Taux d'erreur en fonction de la variance de bruit AWGN pour un modèle formé pour une puissance de brouillage de 20 dB. Deux utilisateurs actifs.....	52
Figure III.6: Taux d'erreur en fonction de la puissance du brouilleur pour un modèle formé pour une puissance de brouilleur de 20 dB, une variance AWGN de -10 dB et cinq utilisateurs actifs.....	52
Figure III.7: Taux d'erreur en fonction de la puissance du brouilleur pour un modèle formé pour une puissance de brouillage de 20 dB, la variance AWGN est -10 dB et deux utilisateurs actifs.....	53
Figure III.8: Illustration d'un système MIMO massif de formation de faisceau hybride à cellule unique et bande étroite.....	54
Figure III.9: schéma synoptique matériel simplifié du système MIMO massif multi-utilisateurs de BH à cellule unique de liaison descendante basé sur un codeur automatique.....	56
Figure III.10: Comparaison du BER pour différents nombres d'utilisateurs $K = 2, 4$. Les paramètres sont définis comme $N_r^{rf} = 2, N_t^{rf} = KN_r^{rf}$ et le flux de données total est $KN_s = 2 \times K$	59
Figure III.11 : Comparaison avec certaines méthodes existantes. Les paramètres sont définis comme $K = 2, N_t^{rf} = N_r^{rf} = 2$ et le flux de données total est $KN_s = 4$	59

Liste des Tableaux

Tableau I.1: types de Petits cellules.....	13
Tableau II.1 : Résumé des outils et techniques permettant de déployer le deep Learning dans les systèmes mobiles.....	35
Tableau II.2: Résumé des avantages de l'application de l'apprentissage en profondeur pour résoudre les problèmes des réseaux mobiles et sans fil.....	37
Tableau III.3: Disposition du réseau neuronal. Les paramètres entraînaibles sont 6,373.....	44
Tableau III.2: Disposition pour une cellule donnée avec $L = 4$ et $K = 5$. Paramètres entraînaibles: 509,829.....	45
Tableau III.3: Disposition pour une cellule donnée avec $L = 4$ et $K = 5$; Paramètres entraînaibles:509,829.....	46

Liste des Acronymes

1G	Premier Génération
2G	Deuxième Génération
3G	Troisième Génération
4G	Quatrième Génération
5G	Cinquième Génération
3GPP	3rdGeneration Partnership Project
AR	Augmented reality
AWGN	Additive White Gaussian Noise
AE	Autoencoder
BBU	Baseband Unit
BS	Stations de Base
BER	Bit error rate
BF	Beamforming
C-RAN	CloudRAN
CN	Core Network
CSI	Channel State Information
CNN	Convolutional Neural Network:
CDF	Channel Definition Format
DNHB	Deep neural network Hybrid Beamforming
DL	DownLink
D2D	Device-to-Device
EDGE	Enhanced Data for GSM Evolution
eMBB	Enhanced Mobile Broadband (haut débit mobile amélioré)
FDD	Frequency Division Duplex
GPRS	General Packet Radio Service
GSM	Global System for Mobile
HSDPA	High Speed Downlink Packet Access
HSUPA	High Speed Uplink Packet Access
HSPA	High Speed Packet Access
HSPA	Evolved High Speed Packet Access
HetNets	Heterogeneous network
HBF	Hybrid Beamforming
HB	Hybrid Beamforming
IA	L'intelligence artificielle
LTE	Evolution Term Long
LSTM	Long Short- Term Memory
LOT	Internet of Things
MIMO	Multiple-Input Multiple-Output
mMTC	Communication Massive de Type Machine
M2M	Machine-to-machine
ML	Machine learning
MU-MIMO	Multi-user, multiple-input, multiple-output
MSE	Mean Squared Error
MR	Maximum Ratio
MMSE	Minimum mean squared error

MFB	Match filter bank
MO	Optimisation de manifold
MMS	Stands for Multimedia Messaging Service
NR	New Radio
NFV	Network Function Virtualization (virtualisation des fonctions réseau)
NOMA	Non Orthogonal Multiple Access
NS	Network Slicing
NNs	Neural Network Society
NN	Neural network
OFDM	Orthogonal frequency-division multiplexing
OMP	Orthogonal matching pursuit
PNL	Pseudo Natural Language
QoS	Quality of Service
QPSK	Quadrature Phase Shift Keying
RAN	Radio access network
RF	Radio frequency
RDD	Reduced dimension decorrelating
SMS	Stands for Short Message Service
SDN	Software-defined networking (réseaux définis par logiciel)
SCN	Small cellular networks
SDMA	Space Division Multiple Access
SE	Spectral Efficiency
TDD	Time Division Duplex.
URLLC	Ultra Reliable Low Latency Communications
VR	Virtual Reality
UE	User Equipment

Sommaire

Remerciments.....	II
Dédicaces.....	III
Résumé.....	V
Abstract.....	V
Liste des Figures.....	VII
Liste des Tableaux	IX
Liste des Acronymes.....	X
Introduction Generale	1
Chapitre I :Réseaux de la Cinquième Génération (5G)	
I.1.Introduction	4
I.2.Evolution des générations des réseaux mobiles.....	4
1G: Voix seulement	4
2G: SMS et MMS.....	4
3G : Plus de données, d’appels vidéo et d’Internet mobile.....	5
4G: Norme actuelle	5
5G : Si vous devez commander quelque chose quelque part, vous pouvez le faire en quelques secondes sur votre appareil intelligent.....	5
I.3.Fonction de 5G.....	6
I.4. Avantages du réseau 5G.....	6
I.5. Cas d'utilisation de la 5G : URLLC eMBB Mmtc.....	7
I.6. 5G NR (new radio).....	8
I.7. Les technologies utilisées pour la 5G.....	8
I.7.1.Onde millimétrique (Millimeter Waves).....	9
I.7.1.1. Caractéristiques de l’onde millimétrique.....	9
I.7.1.2.Le spectre 5G onde millimétrique	10
I.7.1.3.Le début de la révolution 5G onde millimétrique.....	10
I.7.1.4.Les défis du déploiement 5G onde millimétrique.....	11

I.7.1.5. Paramètres des ondes millimétriques.....	11
I.7.1.6 .Applications de la communication par ondes millimétriques.....	12
I.7.2. Petite cellule (Small cell)	13
I.7.2.1. Que sont les petites cellules (small cell) dans la technologie 5G?.....	13
I.7.2.2. Pourquoi la 5G nécessite de petites cellules (small cell)?.....	14
I.7.2.3. Comment fonctionne une petite cellule (small cell)?.....	14
I.7.2.4. Facteurs affectant la couverture cellulaire et la capacité des données	14
I.7.3. MIMO Massive.....	14
Qu'est-ce que MIMO ?.....	15
I.7.3.1. Comment fonctionne MIMO massif ?.....	16
I.7.3.1.1.Estimation du canal.....	16
I.7.3.1.2.Transmission de données en liaison montante (uplink).....	16
I.7.3.1.3.Transmission de données en liaison descendante (downlink)	17
I.7.3.2. Quels sont les avantages de Massive MIMO?.....	17
I.7.4. Formation de faisceaux (beamforming).....	17
I.7.5. Plein – duplex (Full - duplex).....	18
I.7.6. Internet des objets (IoT).....	19
I.7.7. Multiplexage NOMA (accès multiple non orthogonal).....	19
I.7.8. Communication Device-to-Device (D2D)	19
I.7.9.Prise en charge native de la communication machine-to-machine (M2M).....	20
I.8.La nouvelle architecture de la 5G.....	20
I.8.1.L’infrastructure et les services réseau sont séparés.....	20
I.8.2.Réseau d'accès radio (Radio Access Network (RAN)).....	20
I.8.3.Network Function Virtualization (Virtualisation de la fonction réseau (NMF))	20
I.8.4.Réseaux définis par logiciel (SDNs).....	21
I.8.5.CloudRAN (C-RAN).....	21

I.8.6.Core Network (CN)	21
I.8.7.Network Slicing (Tranchage du réseau (NS))	22
I.9.Conclusion.....	22
Chapitre II : Deep Learning (L'apprentissage En Profondeur)	
II.1.Introduction.....	24
II .2. Qu'est-ce que l'apprentissage en profondeur (Deep learning) ?.....	24
II.2.1. L'intelligence artificielle.....	25
II.2.2. L'apprentissage automatique.....	25
II.2.3. L'apprentissage profond	26
II.2.3.1. Méthodes d'apprentissage en profondeur.....	26
II .2.3.2. Pourquoi d'apprentissage en profondeur?.....	27
II.3. L'apprentissage profond et d'apprentissage automatique.....	27
II.3.1. Fonctionnement des algorithmes d'apprentissage automatique ?.....	28
II.3.2. Algorithmes l'apprentissage profond.....	28
II.3.2.1. Les différents types Algorithmes d'apprentissage profond.....	28
II.4.Réseaux de neurones artificiels	29
II.4.1.Définition.....	29
II.4.2.Comment ça marche un réseau de neurones ?.....	29
II.4.3. Les différents types de réseaux de neurones	31
II.5. Principes fondamentaux de l'apprentissage profond	31
II.6. Propagation avant et arrière	31
II.7.Exemples de domaines d'application.....	33
II.8.Activation de l'apprentissage profond dans les réseaux 5G.....	34
II.8.1. Progression de l'apprentissage profond dans les systèmes mobiles.....	35
II.9. Apprentissage profond alimenté par des réseaux mobiles et sans fil.....	36
II.10. Avantages du Deep Learning dans les réseaux mobiles et sans fil.....	36
II.11. Limitations de l'apprentissage profond dans les réseaux mobiles et sans fil.....	38
II.12.Conclusion	38

Chapitre III: Exemples, Résultats et Discussions

III.1. Introduction	41
III.2.Exemple 1: Deep learning pour l'allocation de puissance dans un système MIMO massif.....	41
III.2.1. Allocation de puissance.....	41
III.2.2. Allocation de puissance basée sur l'apprentissage profond.....	42
III.2.3. Evaluation des performances	43
III.2.3.1.Max-prod	44
III.2.3.2.Max-min.....	46
III.3. Exemple 2: Modèle d'apprentissage en profondeur orienté pour la suppression des brouillages dans les systèmes de connectivité massive.....	47
III.3.1.Algorithme proposé	47
III.3.2.Suppression de brouillage basée sur la liaison descendante.....	47
III.3.3.Détection de symboles	49
III.3.4.Etude de simulation	50
III.4. Exemple 3: Formation de faisceaux hybride pour MIMO à onde millimétrique: une approche d'apprentissage automatique.....	53
III.4.1.Modèle du système	53
III.4.2.Formulation du problème.....	55
III.4.3.conception d'un beamformer hybride basée sur AE.....	56
III.4.3.1.Conception de formateur / combineur numérique.....	56
III.4.3.2.Conception de formateur / combineur de faisceaux analogiques ...	57
III.4.3.3.Transmission par canal.....	58
III.4.3.4.Formation des problèmes d'optimisation	58
III.4.4.Résultats de simulation	58
III.5 :Conclusion	60
Conclusion Générale	61
Références bibliographiques	63

Introduction générale

Nous sommes encore actuellement avec la révolution de quatrième génération, qui est une technologie à haut débit capable de fournir des vitesses Internet élevées avec l'ajout de quelques développements et mises à jour dans les réseaux qui peuvent atteindre environ 300 mégaoctets et c'est une chose impressionnante ... alors de quoi avons-nous besoin de plus que cela dans ce monde? Eh bien, venez imaginer ... une voiture autonome communique immédiatement avec tous les feux de signalisation et autres voitures un chirurgien utilise des dispositifs d'intelligence artificielle et des gants spéciaux pour effectuer une opération sur un patient à des milliers de kilomètres des villes intelligentes ... des maisons connectées les unes avec les autres complètement ... des robots partout ... pour la 5G changeront la donne ... c'est l'avenir ... qui sera alimenté par la technologie 5G.

La 5G est la prochaine génération de réseaux sans fil, et il sera près de dix fois la vitesse de la 4G, il faut donc environ 6 minutes pour télécharger un film 3D en 4G, mais avec la 5G, cela ne prendra que 30 secondes. La 5G n'est pas seulement une vitesse de téléchargement et de téléchargement uniquement, elle est liée à la connexion à l'Internet des objets, et elle permettra d'atteindre ce que l'on appelle hyper-connecté, c'est-à-dire la connexion des personnes et des équipements entre eux, et le flux d'informations sera fluide et continu avec l'obtention des niveaux de couverture les plus élevés et une vitesse illimitée grâce à cette technologie qui promet des débits de données. Une densité de connexion plus rapide et plus élevée, une latence beaucoup plus faible, une économie d'énergie significative et s'efforce de répondre aux besoins de tous les utilisateurs.

La 5G utilisera pour la première fois dans le domaine des communications sans fil le spectre haute fréquence ou ce que l'on appelle les ondes millimétriques, qui se caractérise par des fréquences élevées allant de 6 GHz à 100 GHz, qui a une longueur d'onde très courte capable de fournir des vitesses plus élevées que tout autre spectre et prendra également en charge la bande passante pour obtenir un débit de transfert de données plus élevé. La technologie massive MIMO est également adoptée en premier pour améliorer le système d'exploitation du système; Les ressources spectrales d'ondes millimétriques sont utilisées pour étendre la bande passante du système; et des réseaux multicouches et hyper-densité pour augmenter la réutilisation du spectre géographique. Les systèmes qui utilisent d'énormes réseaux d'antennes pour desservir plusieurs utilisateurs sont appelés systèmes de communication de masse MIMO. Il est capable de lutter contre l'atténuation du signal millimétrique, de fournir une connectivité sans fil et de supprimer les interférences dans les réseaux multicouches et plus denses.

Avec la 5G mmWave qui commence à se répandre dans les petits réseaux cellulaires à faible coût et en utilisant la technologie d'antenne MIMO massive pour fournir des taux de

Introduction Générale

téléchargement allant jusqu'à 20 Gbps aux utilisateurs, l'énorme promesse deviendra évidente et cela fait partie de la révolution 5G. À ce stade, il y aura probablement une explosion du nombre de nouvelles applications et de scénarios de déploiement exploitant la nouvelle technologie. La combinaison de mmWaves, de MIMO massif et de petites cellules peut être considérée comme une solution technologique majeure pour la communication mobile 5G [1].

L'adoption rapide des appareils mobiles et la popularité croissante des applications et des services mobiles imposent des exigences sans précédent aux infrastructures de réseaux mobiles et sans fil. Les systèmes 5G à venir évoluent pour prendre en charge d'énormes volumes de trafic mobile, l'extraction en temps réel de matériaux d'analyse précis et une gestion allégée des ressources réseau, afin de maximiser l'expérience utilisateur, et l'accomplissement de ces tâches est difficile, car les environnements mobiles deviennent de plus en plus complexes, hétérogènes et sophistiqués. Une solution potentielle consiste à utiliser des techniques avancées d'apprentissage automatique pour aider à gérer l'augmentation des volumes de données et des applications algorithmiques. Le récent succès de l'apprentissage en profondeur soutient de nouveaux outils puissants qui abordent les problèmes dans cet espace [2] qui joue un rôle essentiel dans les réseaux sans fil et mobiles.

L'objectif de notre travail est d'étudier l'emploi du deep learning dans les réseaux mobiles 5G. Le premier chapitre présente une étude complète de l'évolution des réseaux de communication mobile et de l'importance de la technologie 5G et de ses principaux avantages. Le deuxième chapitre explique une vue générale sur l'apprentissage profond, l'une des branches de l'apprentissage automatique, et montre également comment cet apprentissage s'intègre dans les réseaux mobile de la 5G. Enfin, nous avons présenté trois applications importantes de l'apprentissage en profondeur qui sont des exemples d'amélioration de l'utilisation de l'apprentissage en profondeur qui ont fourni des informations précieuses pour un avenir proche. Et avec ça, nous finissons notre travail par une conclusion générale.

Chapitre I :
Réseaux de la Cinquième Génération (5G)

I.1.Introduction :

Dans un avenir proche, une technologie moderne dite la 5G sera lancée. Cette nouvelle génération de normes de téléphonie mobile a été certifiée par l'Union internationale des télécommunications 3 GPP , par rapport à la technologie 4G LTE actuelle visant le réseau physique de cinquième génération, ce dernier sera relié à Internet dans le cadre du nouveau concept d'Internet des objets LOT, il aura une augmentation dans la vitesse et la réponse (1 Gbit / s), et les réseaux de cinquième génération seront en mesure d'obtenir une augmentation significative de la quantité de données envoyées sur les systèmes sans fil en raison de la bande passante accrue et des technologies d'antenne avancées, où les données transférées peuvent être transférées à des taux allant jusqu'à 20 gigaoctets par seconde, faible consommation d'énergie et faible latence (1 ms), capacité de mise en réseau, robots, maison intelligente

Dans ce premier chapitre, nous montrerons comment l'infrastructure de réseau mobile 5G a été développée avec une conception innovante, adaptative et robuste pour les développements futurs. Dans ce chapitre, nous décrivons la technologie 5G qui peut conduire à la fois à des changements de conception architecturale et à des composants perturbateurs: ondes millimétriques, MIMO massif, appareils plus intelligents.

I.2.Evolution des générations des réseaux mobiles:**➤ 1G: Voix seulement :**

Les téléphones portables 1G sont apparus dans les années 1980. C'est la première génération de technologie cellulaire sans fil. 1G ne prend en charge que les appels vocaux, mais la transmission de données n'était pas dans l'image à l'époque, et les réseaux qui utilisaient ce signal étaient des réseaux analogiques. Les téléphones utilisant 1G ont une autonomie de batterie médiocre, une faible qualité sonore et une faible sécurité.

La vitesse maximale de la technologie 1G est de 2,4 Kbps.

➤ 2G: SMS et MMS:

Les premiers systèmes cellulaires numériques lancés au début des années 1990 (de l'analogique aux communications numériques). Avec le soutien de GSM introduit la technologie de téléphone 2G, les communications numériques ont permis des améliorations significatives de la qualité sonore et la capacité du réseau, ainsi que des services de données tels que SMS, messages d'image et MMS. 2G vitesse maximale mms

avec GPRS 50. Kbps. La vitesse est de 1 Mbps avec des taux de données améliorés pour le développement de GSM (EDGE).

➤ **3G : Plus de données, d'appels vidéo et d'Internet mobile:**

Il marque le début de la révolution technologique dans la communication cellulaire où l'introduction de réseaux 3G en 1998 a conduit à des vitesses de transfert de données plus rapides, de sorte que vous pouvez utiliser votre téléphone cellulaire de manière plus exigeante telle que les appels vidéo et l'accès Internet mobile.

Pour la première fois, le terme «haut débit mobile» a été appliqué à la technologie cellulaire de troisième génération. La vitesse maximale de la troisième génération est estimée à environ 2 Mbps pour les appareils non mobiles et 384 kbps dans les véhicules mobiles. La 3G a rapidement évolué en 3.5G et 3.75G et aux évolutions de cette norme (HSDPA, HSUPA, HSPA, HSPA+) à mesure que de nouvelles fonctionnalités ont été introduites pour réaliser le lancement de la 4G.

➤ **4G: Norme actuelle :**

La quatrième génération de réseaux, publié en 2008, prend en charge l'accès au Web mobile tels que la 3G et aussi les services de jeux, la télévision mobile HD, la vidéoconférence, la télévision 3D et d'autres fonctionnalités qui nécessitent des vitesses élevées. La vitesse maximale d'un réseau 4G lorsque l'appareil se déplace est de 100 Mbps. La vitesse est de 1 GOps pour les connexions à faible mouvement.

LTE (Evolution Term Long), une nouvelle norme pour les réseaux 4G dans les communications sans fil à large bande, fournit des vitesses de transmission de données très élevées. LTE transmet des données vocales et d'images dans une cellule de rayon avec jusqu'à 100 km de support pour contenir la station de base BS et utilise la technologie et le codage de l'OFDM pour fournir des liens descendants et à venir pour transférer des données, améliorant la flexibilité du spectre et la rentabilité.

➤ **5G : Si vous devez commander quelque chose quelque part, vous pouvez le faire en quelques secondes sur votre appareil intelligent.....**

5G est une nouvelle génération des dernières technologies cellulaires dans le téléphone mobile. Cette technologie de communication sans fil promet de révolutionner la façon dont le monde communique. Il a été développé pour augmenter la vitesse des réseaux sans fil, la technologie 5G peut gérer des milliers de trafic par rapport aux réseaux d'aujourd'hui qui sont 10 fois plus rapides que la 4G, que la société 5G promet des taux de données beaucoup plus rapides, vous pouvez télécharger des fichiers vidéo et des fichiers

multimédias que dans les secondes, et encore moins de temps de réponse, économiser de l'énergie, Et des connexions plus intensives et fiables que jamais sur les appareils intelligents et autres appareils, la 5G est à la base de la VR (réalité virtuelle) et de l'IoT (Internet des objets). La vitesse théorique prévue des connexions 5G est jusqu'à 20 Gbps. Les appareils basés sur la technologie 5G fonctionnent dans de nombreuses bandes de 3 à 300 GHz, les gammes de fréquences inférieures à 6 GHz sont utilisées pour la macro optimisée 5G, 3 à 30 GHz pour les petites cellules 5G, 30 à 100 GHz pour la 5G Ultra Dense et 30 à 300 GHz est utilisé pour les ondes millimétriques 5G.




Figure I.1: les générations des réseaux mobiles

I.3.Fonction de 5G :

- La 5G a une meilleure zone de couverture et un débit de données élevé au bord de la cellule.
- Latence inférieure par rapport à LTE.
- Pour prendre en charge les appareils dans l'Internet des objets.
- Capacité supérieure à 4G.
- Grand nombre de connexions simultanées pour les capteurs sans fil.
- Il a une faible consommation de batterie.
- Disponibilité de plusieurs taux de transfert de données.
- Un débit de données d'environ 1 Gbit/s est facilement possible.
- La sécurité, c'est plus et Couverture améliorée.
- L'efficacité énergétique et l'efficacité spectrale sont bonnes.

I.4. Avantages du réseau 5G :

- La technologie 5G prend en charge des services hétérogènes et peut fournir une connexion unifiée, discontinue et cohérente dans le monde entier, vous pouvez connaître la météo et l'emplacement tout en parlant à l'autre personne, vous pouvez contrôler vos

ordinateurs via des téléphones, le réseau 5G vous aidera à surfer sur le Web, à télécharger des fichiers et à diffuser rapidement des vidéos [3].et Standardiser la technologie de reconnaissance vocale dans les interfaces utilisateurs [4]

□ L'organisation gouvernementale peut surveiller n'importe quelle partie du monde, il est possible de réduire le taux de criminalité, la visualisation de l'univers, des galaxies et des planètes sera possible, il est possible de localiser et de rechercher des personnes disparues, les catastrophes naturelles, y compris les tsunamis et les tremblements de terre, peuvent être découverts plus rapidement, et un réseau fournit la 5G est continue et permet d'accéder à plusieurs services parallèles et peut atteindre des emplacements distants[3].

□ Le réseau 5G peut augmenter la bande passante pour tous les utilisateurs, et la bande passante est la quantité «d'espace» disponible pour les personnes qui utilisent des données pour télécharger des fichiers, afficher des pages Web, regarder des vidéos, et moins la bande passante est disponible, plus les appareils de chacun seront lents lors de l'exécution [3].

I.5. Cas d'utilisation de la 5G :

La 5G a 3 classes distinctes de cas d'utilisation: communication massive de type machine (mMTC), haut débit mobile amélioré (eMBB) et communication ultra-fiable et à faible latence (URLLC) [5]:

□ mMTC fait référence à la connectivité pour un nombre massif d'appareils à très faible coût et une très faible consommation d'énergie. Des dispositifs tels que les réseaux de surveillance, les capteurs, les actionneurs (etc.) offrent une disponibilité à long terme en augmentant la durée de vie et la couverture de la batterie.

□ eMBB correspond à un échange de données plus important entre les nœuds et l'équipement des utilisateurs. La réalité augmentée (AR), la réalité virtuelle (VR), le cloud computing sont des exemples de cas d'utilisation d'eMBB.

□ URLLC signifie une latence très faible et une fiabilité extrêmement élevée. Les exemples sont le contrôle automatique, la sécurité routière, les villes intelligentes et l'automatisation d'usine.

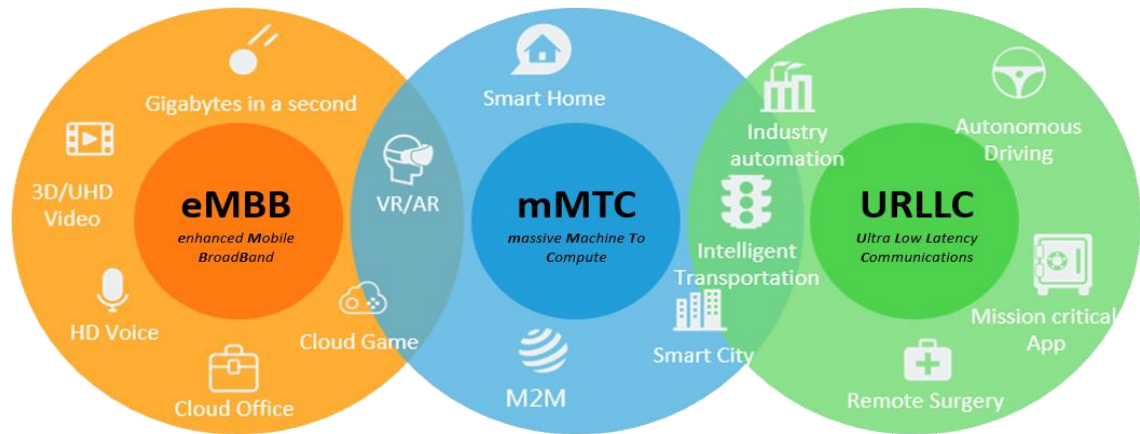


Figure I.2 : Classification des cas d'utilisation de la 5G de haut niveau

I.6. 5G NR (new radio) :

5G NR (nouvelle radio) est la nouvelle norme pour la technologie sans fil 5G capable d'un réseau beaucoup plus rapide, efficace et évolutif. La technologie 5G NR nous permettra de nous connecter à de nombreuses choses dans les environs avec une faible latence et vitesse d'éclairage.

La 5G NR a été conçu pour dimensionner efficacement le réseau au cours des 10 à 15 prochaines années. Toute amélioration future n'affectera pas le réseau existant et des améliorations de performances sont possibles.

Le système 5G NR offrira un réseau beaucoup plus rapide, évolutif et efficace qui peut prendre en charge des milliards d'appareils et des technologies émergentes comme l'Internet des objets. De plus, le spectre sans licence offre des possibilités illimitées en raison d'une bande passante plus élevée, même jusqu'à 500 MHz.

L'un des avantages les plus importants du système 5G NR est sa compatibilité ascendante pour les 10 à 15 prochaines années. 5G NR est capable de nouvelles améliorations dans les années à venir sans interrompre le réseau existant [6].

I.7. Les technologies utilisées pour la 5G :

Les réseaux 5G sont à nos portes et cette nouvelle génération de communication sans fil est alimentée par une nouvelle technologie appelée ondes millimétriques (mmWave).




Figure I.3 : Technologies 5G

I.7.1. Onde millimétrique (Millimeter Waves) :

La demande croissante de canaux de données plus élevés en tant qu'accès sans fil massif et le spectre disponible limité dans les bandes micro-ondes¹ ont motivé l'amélioration de l'efficacité spectrale en utilisant des technologies avancées telles que les communications en duplex intégral, la mise en réseau cognitive et coopérative, l'annulation des interférences et la sortie multiple massive d'entrées multiples (MIMO). Alors que ces améliorations atteignent les limites de capacité fondamentales, la bande d'ondes millimétriques (mmWave) devient une option alternative et prometteuse pour prendre en charge l'accès sans fil à très haut débit [7].

I.7.1.1. Caractéristiques de l'onde millimétrique :

Les systèmes cellulaires à ondes millimétriques (mmWave), qui fonctionnent dans la bande 30-300 GHz, semblent être un candidat de bon augure pour le système cellulaire 5G de nouvelle génération, qui devrait prendre en charge des débits de données de plusieurs Gb / s. Cependant, l'utilisation de mmWave nécessite de traiter les attributs de propagation et les dégradations de canal des bandes haute fréquence [8].

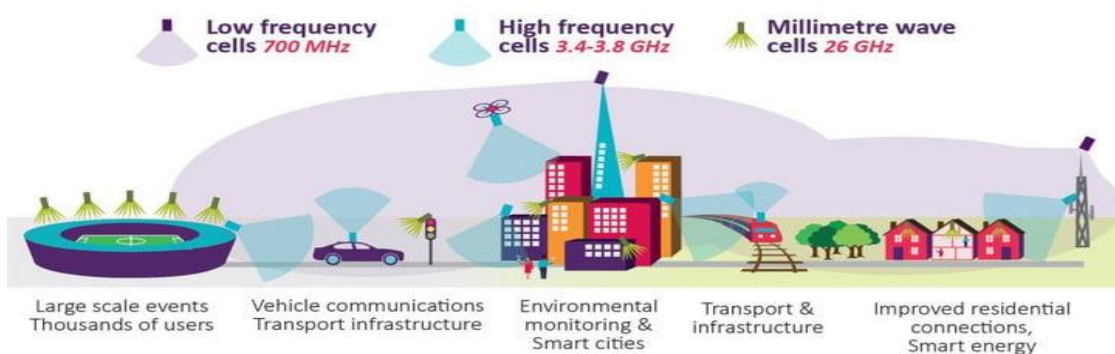


Figure I.4 :Bande d'ondes millimétriques

La gamme des services 5G s'étend à des bandes de fréquences beaucoup plus élevées qui n'ont pas été prises en compte par les télécommunications, Il utilise les bandes de fréquences comprises entre 24 GHz et 100 GHz, ce qui présente de nouveaux défis et avantages pour les réseaux 5G[8].

I.7.1.2.Le spectre 5G onde millimétrique :

L'incroyable demande de bande passante de données sans fil ne montre aucun signe de ralentissement dans un avenir prévisible. Dans le même temps, l'expérience des données mobiles pour les utilisateurs continue de s'étendre et de se développer, ce qui exerce une pression croissante sur l'utilisation en réseau du spectre sans fil disponible. Avec cette croissance projetée à l'esprit, l'industrie cellulaire s'est tournée vers d'autres bandes de fréquences qui pourraient éventuellement être utilisées dans le développement de nouvelles technologies sans fil 5G. Les bandes à haute fréquence dans le spectre au-dessus de 24 GHz ont été ciblées comme pouvant prendre en charge de larges bandes passantes et des débits de données élevés, idéales pour augmenter la capacité des réseaux sans fil. Ces bandes haute fréquence sont souvent appelées «mmwave» en raison des courtes longueurs d'onde qui peuvent être mesurées en millimètres. Bien que les bandes mmWave s'étendent jusqu'à 300 GHz, ce sont les bandes de 24 GHz à 100 GHz qui devraient être utilisées pour la 5G. Les bandes mmWave jusqu'à 100 GHz sont capables de prendre en charge des bandes passantes jusqu'à 2 GHz, sans avoir besoin d'agréger les bandes ensemble pour un débit de données plus élevé [9].




Figure I.5 : Le spectre 5G onde millimétrique

I.7.1.3.Le début de la révolution 5G onde millimétrique :

La mise en œuvre de nouvelles normes mobiles 5G et l'utilisation du spectre onde millimétrique devraient être révolutionnaires. Les bandes onde millimétrique mises à disposition pour les réseaux mobiles fourniront des performances accrues, une meilleure couverture et une intégration plus étroite entre plusieurs technologies sans fil de 4G LTE

au Wi-Fi, en dessous de 6 GHz 5G, ainsi que l'extension aux bandes 5G mmWave à fréquence plus élevée. Alors que 5G onde millimétrique commence à être déployé dans des réseaux à petites cellules à faible coût utilisant des antennes MIMO massives pour fournir jusqu'à 20 Gbps de taux de téléchargement aux utilisateurs, l'immense promesse de la 5G deviendra évidente[9].

I.7.1.4. Les défis du déploiement 5G onde millimétrique:

L'utilisation de la bande de fréquences supérieure à 6 GHz est jugée inappropriée pour les communications en raison des pertes de propagation élevées, de la pénétration et de la facilité de blocage des signaux. Malgré les défis difficiles qui limitent la propagation des ondes millimétriques, qui seront plus petites et plus intenses, les nouvelles technologies d'antenne permettent un certain nombre de scénarios de déploiement.

Une adaptation rapide aux conditions changeantes des canaux permettra également la commutation à l'intérieur et entre les cellules pour maintenir les performances et la couverture [9]. En outre, les réseaux définis par logiciel (SDN) et la virtualisation des fonctions réseau (NFV) joueront un rôle important dans le fonctionnement des réseaux et la communication facile entre les utilisateurs.

I.7.1.5. Paramètres des ondes millimétriques :

Bande passante : le principal avantage de la technologie des ondes millimétriques sur les fréquences RF est la bande passante spectrale de 5 GHz disponible dans ces gammes, ce qui permet des vitesses actuelles allant jusqu'à 10 Gbit/s en duplex intégral avec des vitesses de débit potentielles allant jusqu'à 10 Gbit/s en duplex intégral rendues possibles [10].

Sécurité : comme les ondes millimétriques ont une largeur de faisceau étroite et sont bloquées par de nombreuses structures solides, elles créent également un niveau de sécurité inhérent. Afin de renifler un rayonnement millimétrique, un récepteur doit être installé très près ou sur le chemin de la connexion radio. La perte d'intégrité des données causée par une antenne renifleuse fournit un mécanisme de détection pour les réseaux attaqués [10].

Résistance aux interférences de largeur de faisceau : Les signaux d'ondes millimétriques transmettent dans des faisceaux focalisés très étroits, ce qui permet plusieurs emplois à courte portée en utilisant les mêmes plages de fréquences. Cela permet une onde millimétrique idéale pour les topologies de réseau maillé, annulaire et concentrateur dense à rayons point à point où les signaux de fréquence inférieure ne

seraient pas être capable de faire face avant que les interférences de signaux croisés ne deviennent un facteur limitant important[10].

I.7.1.6 .Applications de la communication par ondes millimétriques :

La plage des ondes continues cohérentes millimétriques et submillimétriques est riche en applications scientifiques et technologiques [11]. Ici on va citer quelques applications sur les ondes millimétriques :

A : Accès aux petites cellules :

Les petites cellules déployées sous-jacentes aux macro-cellules et fournissent une solution pour l'amélioration de la capacité dans les réseaux 5G. Avec une bande passante énorme, les petites cellules à ondes mm sont capables de fournir les débits en gigabits. Les petites cellules chiffrent toutes les voix et données envoyées et reçues [10].




Figure I.6: Propagation des ondes 5G

B : backhaul sans fil :

Avec de petites cellules densément déployées dans la prochaine génération de système cellulaire 5G, il est coûteux de connecter les stations de base BS aux autres BS et au réseau par liaison terrestre à fibre. En revanche, le backhaul sans fil haute vitesse avec un faible coût, flexible et plus facile à déployer.

Avec une bande passante énorme disponible, le backhaul sans fil dans les bandes d'ondes mm, telles que la bande 60 GHz et la bande E (71-76 GHz et 81-86 GHz), fournit des débits de données de plusieurs Gbps et peut être une solution de backhaul prometteuse pour les petites cellules [10].

C: propagation des ondes millimétriques :

Les caractéristiques de propagation de la bande d'ondes millimétriques sont très différentes de celles en dessous de 4GHz. Les distances qui peuvent être atteintes sont généralement beaucoup moins importantes et les signaux ne traversent pas les murs et autres objets dans les bâtiments.

En règle générale, la communication par ondes millimétriques est susceptible d'être utilisée pour des zones de couverture extérieure comprises entre 200 et 300 mètres [10].

I.7.2. Petite cellule (Small cell) :

I.7.2.1. Que sont les petites cellules (small cell) dans la technologie 5G?

Les petites cellules sont des systèmes de transmission sans fil à faible puissance et à courte portée (stations de base) pour couvrir une petite zone géographique ou des applications intérieures / extérieures. Cependant, les petites cellules ont toutes les caractéristiques de base des stations de base conventionnelles et sont capables de gérer un débit de données élevé pour les utilisateurs individuels. Les petites cellules seront une caractéristique majeure des réseaux 5G, en particulier aux nouvelles fréquences d'onde millimétrique (mmWave) où la plage de connexion est très courte. Pour fournir une connexion continue, les petites cellules seront réparties en grappes selon l'endroit où les utilisateurs ont besoin d'une connexion qui complètera le macro-réseau qui fournit une couverture étendue. Les premières indications suggèrent que les réseaux hétérogènes (HetNets) et les petits réseaux cellulaires (SCN) vont être des éléments importants des systèmes 5G, en particulier pour faciliter le trafic de données massif et la connectivité omniprésente pour les utilisateurs. Dans HetNets, de petites cellules de différentes tailles sont intégrées dans un réseau macrocellulaire existant, qui aide à surmonter les problèmes de spectre limité et d'efficacité énergétique [12][13].



Figure I.7 : Petite cellule (Small cell).

type	Puissance de sortie	Rayon de la cellule	nombre d'utilisateur	location
femtocell	1mw - 250mw	10m – 100m	1 - 20	intérieur
picocell	250mw – 1w	100m – 200m	30 -100	Intérieur / extérieur
microcellule	1w – 10w	200m – 2km	100 -2000	Intérieur/extérieur
macrocellule	10w – 50+w	8km – 30km	2000+	extérieur

Tableau I.1: types de Petits cellules.

Les macro-cellules 5G utiliseront des antennes MIMO (entrées multiples, sorties multiples) qui ont plusieurs éléments ou connexions pour envoyer et recevoir plus de données simultanément.

I.7.2.2. Pourquoi la 5G nécessite de petites cellules (small cell)?

La technologie 5G a été conçue pour se concentrer sur trois domaines majeurs tels que:

1. Haut débit mobile amélioré.
2. Réseau ultra fiable et à faible latence.
3. IoT massif.

I.7.2.3. Comment fonctionne une petite cellule (small cell)?

Les petites cellules fonctionnent à l'aide de technologies avancées telles que MIMO, la formation de faisceaux et les ondes millimétriques pour la transmission. En utilisant le concept de petites cellules, les stations de transmission de faible puissance peuvent être déployées facilement. Les petites unités de dispositifs cellulaires sont également conçues pour réduire la complexité et ainsi faciliter et accélérer la mise en œuvre.

Pour les applications intérieures, les petites stations de base (émetteurs et récepteurs) sont installées sur le mur. Pour les applications extérieures, de petites tours ou des lampadaires sont utilisés. Les connexions par patch peuvent être effectuées à l'aide de connexions fibre, filaires et micro-ondes.

I.7.2.4. Facteurs affectant la couverture cellulaire et la capacité des données :

Fréquence: La bande passante du signal dépend de la fréquence, et la fréquence la plus élevée a une bande passante plus élevée à utiliser, cette dernière étant sujette à une distorsion plus élevée et a un taux de pénétration plus faible.

Puissance: Parmi les facteurs limitant la zone de couverture cellulaire, il y a la puissance de transmission afin que les émettrices hautes puissances puissent couvrir une zone environnante plus large.

Technologies d'antennes: (MIMO) contribue de manière significative à la couverture cellulaire et au débit de données en termes de nombre et d'angle, de hauteur des réseaux d'antennes.

I.7.3. MIMO Massive :

La technologie massive MIMO sera un composant majeur des réseaux 5G à haut débit, et elle a été intégrée dans des normes haut débit sans fil telles que LTE et Wi-Fi.

Qu'est-ce que MIMO ?

Auparavant, chaque appareil sans fil avait une antenne dans l'émetteur et une antenne dans le récepteur, et cette antenne est responsable de l'envoi et de la réception de toutes les données. Actuellement, les scientifiques ont découvert que l'ajout d'un grand groupe d'antennes dans le récepteur et d'un groupe d'antennes dans l'émetteur augmente la capacité des appareils à transmettre et recevoir plus de données et à gérer plus d'erreurs. , Il sortira d'un grand groupe d'utilisateurs et d'une plus grande vitesse du réseau.

Massive MIMO est une forme de système MU-MIMO. Ce concept indique que le nombre d'antennes BS et le nombre d'utilisateurs est très important, cette technologie dessert des centaines ou des milliers d'antennes BS en même temps des dizaines ou des centaines d'utilisateurs dans la même source de fréquence.




Figure I.8: Illustration de la liaison descendante Massive MIMO en communication en visibilité directe.

En bref, MIMO est utilisé dans le système sans fil pour diriger le paquet d'antenne vers l'utilisateur, l'amélioration du gain d'antenne et la réduction des interférences pour les autres utilisateurs. Nous mentionnons quelques points clés de Massive MIMO:

- **Fonctionnement TDD:** Le MIMO massif a été conçu à l'origine pour la transmission double fraction de temps (TDD), mais peut également être appliqué dans le processus de division à double fréquence (FDD)[14].avec FDD, le surdébit d'estimation de canal dépend du nombre d'antennes de station de base M . En revanche, avec TDD, le surdébit d'estimation de canal est indépendant de M . Dans Massive MIMO, M est grand, et par conséquent, le fonctionnement TDD est préférable [15].
- Il fonctionne en mode TDD pour limiter le surcoût d'acquisition CSI, dû aux antennes multiples, et pour ne pas s'appuyer sur des modèles de canaux paramétrables [16].

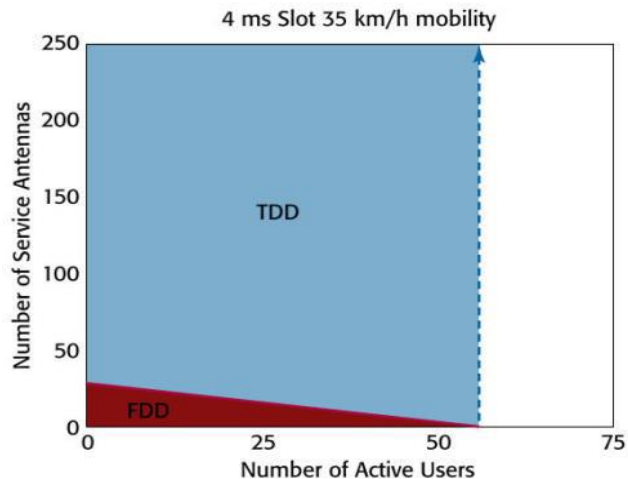


Figure I.9:Les régions des possibles (M, K) dans les systèmes TDD et FDD, pour un intervalle de cohérence de 200 symboles.

- **Traitement linéaire.** Dans Massive MIMO, le traitement linéaire (schémas de peignage linéaire dans la liaison montante (uplink) et schémas de précodage linéaire dans la liaison descendante(downlink)) est presque optimal.
- **Propagation favorable:** une propagation favorable signifie que la matrice de canaux entre le réseau d'antennes BS et les utilisateurs est bien conditionnée [15].
- Il utilise la SDMA pour réaliser un gain de multiplexage en desservant plusieurs UE sur les mêmes ressources temps-fréquence [16].
- Un réseau d'antennes BS massif n'a pas besoin d'être physiquement grand [17].

I.7.3.1. Comment fonctionne MIMO massif ?

Dans Massive MIMO, le fonctionnement TDD est préférable.

Certains points principaux de Massive MIMO sont[15]:

I.7.3.1.1.Estimation du canal :

La BS a besoin de CSI pour détecter les signaux transmis par les utilisateurs dans la liaison montante, et pour précoder les signaux dans la liaison descendante. Ce CSI est obtenu grâce à la formation sur la liaison montante. Chaque utilisateur se voit attribuer une séquence pilote orthogonale et envoie cette séquence pilote à la BS. La BS connaît les séquences pilotes transmises par tous les utilisateurs, puis estime les canaux sur la base des signaux pilotes reçus .

I.7.3.1.2.Transmission de données en liaison montante (uplink) :

Une partie de l'intervalle de cohérence est utilisée pour la transmission de données en liaison montante. Dans la liaison montante, tous les K utilisateurs transmettent leurs

données à la BS dans la même ressource temps-fréquence. La BS utilise ensuite les estimations de canal conjointement avec les techniques de combinaison linéaire pour détecter les signaux transmis par tous les utilisateurs .

I.7.3.1.3. Transmission de données en liaison descendante (downlink) :

Dans la liaison descendante, la BS transmet des signaux à tous les K utilisateurs dans la même ressource temps-fréquence. Plus précisément, la BS utilise ses estimations de canal en combinaison avec les symboles destinés aux K utilisateurs pour créer M signaux précodés qui sont ensuite fournis à M antennes.

I.7.3.2. Quels sont les avantages de Massive MIMO?

Les principaux avantages des systèmes Massive MIMO peuvent être résumés comme suit [18] :

- ✓ Gain d'efficacité spectrale élevé.
- ✓ Gain d'efficacité énergétique élevé.
- ✓ Traitement simple.
- ✓ Augmentation du débit de données.
- ✓ Augmentation du rapport signal sur bruit de liaison de base.
- ✓ Renforcement des canaux.

I.7.4. Formation de faisceaux (beamforming) :

La formation de faisceaux est un type spécial de diagramme de rayonnement d'antenne. C'est une méthode de focalisation de la puissance rayonnée omnidirectionnelle d'une antenne dans une ou plusieurs directions spécifiées. Dans un système 5G, la modulation de faisceau est appelée transmission d'un signal sous une forme plus étroite d'une station de base à un récepteur de telle sorte que seul l'utilisateur visé peut récupérer des informations tout en rejetant les interférences provenant d'autres directions [5].

La formation de faisceaux utilise la puissance émise par les antennes dans une direction spécifique et augmente ainsi la puissance d'un utilisateur spécifique et réduit également les interférences à d'autres endroits; Dans les connexions de courant, la puissance émise par les antennes est dans un circuit dans approximativement la même direction. La focalisation de l'énergie dans une direction spécifique dans un faisceau étroit lui permet d'atteindre une distance supplémentaire et c'est la fonction principale du faisceau de faisceau en rendant les antennes émises au lieu d'être dispersées dans toutes les directions.




Figure I.10: Système Massive MIMO en transmission multi-utilisateurs [19].

En résumé, pensez à la technologie MIMO massive en tant que structure 3D massive augmentant les capacités de couverture horizontale et verticale [1].

I.7.5. Plein – duplex (Full - duplex) :

La communication est appelée full duplex (ou simplement duplex) lorsque nous avons l'émetteur et le récepteur, qui peuvent tous deux transmettre simultanément des données dans les deux sens (transmission bidirectionnelle). Nous pouvons comprendre la ligne bidirectionnelle comme l'équivalent de deux lignes simples, une dans chaque direction.



Figure I.11: Full – duplex.

Les stations de base et les téléphones portables d'aujourd'hui dépendent des émetteurs et des récepteurs, qui doivent tourner si la transmission et la réception d'informations sont sur la même fréquence, ou fonctionner sur des fréquences différentes si l'utilisateur veut envoyer et recevoir des informations en même temps.

Avec la 5G, l'émetteur et le récepteur pourront transmettre et recevoir des données simultanément sur la même bande de fréquence. Cette technique est connue sous le nom de duplex intégral, et elle peut doubler la capacité des réseaux sans fil dans leur couche physique principale [20].




Figure I.12: Émetteur-récepteur duplex intégral.

I.7.6. Internet des objets (IoT) :

L'Internet des objets, également connu sous le nom d'IOT, peut être décrit comme un réseau de gadgets, d'appareils et d'autres éléments constitués d'électronique ou de logiciels installés interconnectés pour échanger des données. Chaque appareil ou appareil est identifiable par son système informatique installé mais a la capacité de fonctionner dans les locaux Internet fournis. L'IOT permet une interaction entre les humains et les appareils / appareils en détectant ou en contrôlant à distance ces appareils, ce qui améliore l'efficacité, la précision, la réduction des efforts humains et un confort maximal [21]. La 5G en particulier permettra à l'IoT de répondre à de nouveaux cas d'utilisation (par exemple, nécessitant une faible latence et une fiabilité élevée) et des secteurs économiques où jusqu'à présent la communication mobile était inexistante[22].

I.7.7. Multiplexage NOMA (accès multiple non orthogonal) :

Plusieurs utilisateurs sont couplés et partagent les mêmes ressources radio, que ce soit en temps, en fréquence ou en code [23]. À un moment précis, chaque extrémité utilise une partie des fréquences pour améliorer l'efficacité spectrale du réseau 5G.

I.7.8. Communication Device-to-Device (D2D) :

La communication D2D de périphérique à périphérique est considérée comme l'un des ingrédients clés des réseaux sans fil 5G.

En général, les avantages résultant du fonctionnement D2D comprennent, entre autres, une efficacité spectrale fortement accrue, un débit de données pour utilisateur et une capacité par zone améliorés, une couverture étendue, une latence réduite et une efficacité accrue en termes de coût et de puissance [24].

I.7.9.Prise en charge native de la communication machine-to-machine (M2M) :

La considération essentielle pour la communication M2M en 5G implique de satisfaire trois exigences fondamentalement différentes associées à différentes classes de services à bas débit : un nombre important d'appareils connectés, une fiabilité de liaison très élevée, une faible latence et un fonctionnement en temps réel [25].

I.8.La nouvelle architecture de la 5G :

En raison de la quantité massive de nouvelles bandes passantes mises à disposition, la croissance importante attendue du nombre d'appareils connectés, de la large gamme d'applications à prendre en charge et des différentes caractéristiques de qualité de service (QoS) des différentes utilisations, l'architecture 5G est conçue d'une manière inédite. Les principales différences entre l'architecture 5G et celles des réseaux 1G à 4G sont les suivantes [26] :

I.8.1.L'infrastructure et les services réseau sont séparés :

Dans le monde de la 5G, les différents systèmes d'infrastructure de réseau - tels que relais, antennes, accès radio Réseaux (RAN), nœuds d'accès alimentant les RAN, réseaux de base, centres de données pouvant fournir des services cloud à l'équipement utilisateur (UE) - sont séparés par une couche « ressources physiques ». En conséquence, l'infrastructure physique n'est pas nécessairement détenue ou exploitée par le même opérateur. Ces ressources (informatiques, stockage, connectivité) sont plutôt considérées comme étant des ressources virtuelles logiques pouvant être exploitées au besoin selon un autre niveau dans l'architecture 5G [26].

I.8.2.Réseau d'accès radio (Radio Access Network (RAN)) :

Il se compose de divers types d'installations, y compris de petites cellules, des tours, des mâts et des systèmes dédiés dans les bâtiments et à domicile qui connectent les utilisateurs mobiles et les appareils sans fil au réseau principal [27].

I.8.3.Network Function Virtualization (Virtualisation de la fonction réseau (NFV)) :

C'est la capacité d'instancier des fonctions réseau en temps réel à n'importe quel endroit souhaité sur la plate forme cloud de l'opérateur. Les fonctions réseau qui fonctionnaient auparavant sur du matériel dédié, par exemple un pare-feu et le chiffrement dans les locaux de l'entreprise, peuvent désormais fonctionner sur des logiciels sur une machine virtuelle. NFV est cruciale pour permettre l'efficacité de vitesse et l'agilité pour prendre en charge de

nouvelles applications commerciales et est une technologie importante pour un cœur prêt pour la 5G [27].

I.8.4. Réseaux définis par logiciel (SDNs) :

La fourniture de services de réseau sera effectuée au moyen d'un système de réseau « virtuel ». Ce dernier traduira les besoins des utilisateurs en instructions utilisables par les « gestionnaires d'infrastructure virtuelle » pour exploiter, si nécessaire, des sections de l'infrastructure physique. Le réseau lui-même devient un concept abstrait puisqu'il y a une complète séparation complète fourniture de services de réseau avec l'infrastructure. Les réseaux, dans le sens actuel du terme, n'existeront plus. Ils seront remplacés à l'intérieur du contexte nouveau créé par le fonctionnement du réseau 5G [26]. Le SDN facilite la configuration, la mise à l'échelle et la gestion de l'infrastructure déployée de réseau [28].

I.8.5. CloudRAN (C-RAN) :

Le C-RAN est aussi connu sous le nom de RAN central. C'est une évolution en SDN . L'architecture de C-RAN décompose la station de base traditionnelle en deux entités ; des têtes radio distantes placées sur les sites cellulaires et des unités de traitement bande de base (BBU) mises en communs dans un pool centralisé. Les deux entités sont liées au moyen d'un réseau de fibre optique (Fibre Radio) [29].




Figure I.13: CloudRAN

I.8.6. Core Network (CN) :

C'est le réseau mobile d'échange de données qui gère toutes les connexions mobiles voix, données et Internet. Pour la 5G, le «réseau principal» est en train d'être repensé pour mieux s'intégrer aux services Internet et cloud et comprend également des serveurs distribués sur le réseau, améliorant les temps de réponse (réduisant la latence)[27].

I.8.7. Network Slicing (Tranchage du réseau (NS)) :

Il permet une façon intelligente de segmenter le réseau pour une industrie, une entreprise ou une application particulière. Par exemple, les services d'urgence pourraient fonctionner sur une tranche de réseau indépendamment des autres utilisateurs. Certaines « tranches » du réseau ne pourront inclure que les transmissions d'ondes du type mmWave, d'autres pourraient intégrer la 4G en cas de mauvaises performances et passer aux vitesses des ondes « mmWave » seulement pour certaines applications [27].

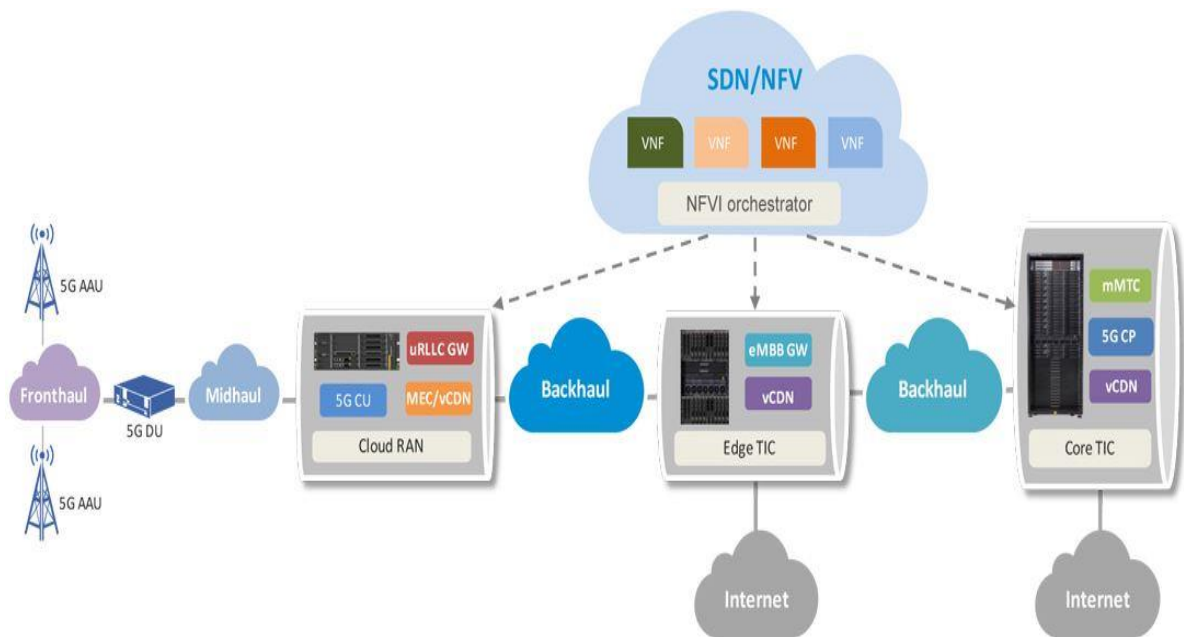


Figure I.14: Architecture de la 5G.

I.9. Conclusion :

La 5G est la norme technologique de cinquième génération pour les réseaux cellulaires. Cette technologie comprend un réseau d'accès sans fil polyvalent pour les applications sans fil mobiles, fixes et d'entreprise. Il comprend toutes sortes de fonctionnalités avancées qui le rendent puissant et très demandé dans un avenir proche. Les principales fonctionnalités 5G offrent une vitesse plus rapide, moins de temps de réponse et la possibilité de connecter plus d'appareils simultanément.

Chapitre II :
Deep Learning (L'apprentissage en Profondeur)

II.1.Introduction :

En raison du nombre croissant de smart phones et de l'émergence d'une grande variété d'applications qui ont conduit à une augmentation significative du trafic de données via le téléphone mobile, alors que nous l'avons mentionné dans le premier chapitre, la cinquième génération suivante se développe pour soutenir l'explosion du trafic mobile afin d'augmenter l'expérience utilisateur au maximum. Parce que les environnements mobiles deviennent de plus en plus complexes, hétérogènes et évolutifs, la diversité croissante et sophistiquée des structures de réseaux mobiles qui rendent le contrôle et la gestion de nombreux éléments de réseau une tâche difficile. Par conséquent, l'utilisation de techniques avancées d'apprentissage automatique (intelligence artificielle) dans les futurs réseaux mobiles est la meilleure solution pour aider à gérer l'augmentation du volume de données et d'applications qui s'appuient sur des algorithmes en développant des systèmes de réseau qui prennent en charge l'apprentissage automatique.

II .2. Qu'est-ce que l'apprentissage en profondeur (Deep learning) ?

Avant d'explorer ce qu'est l'apprentissage en profondeur (Deep learning), nous devons réfléchir un instant à la façon dont un ordinateur peut résoudre les problèmes arithmétiques les plus complexes et les résoudre en quelques secondes, alors qu'il lui est très difficile (avant l'émergence d'algorithmes d'apprentissage automatique) de comprendre des choses qui semblent simples et intuitives pour les humains, telles que reconnaître l'image d'une personne ou faire la différence entre deux types de fruits. Afin de comprendre ce qu'est l'apprentissage en profondeur, nous devons d'abord comprendre sa relation avec l'apprentissage automatique et l'intelligence artificielle, et peut-être la meilleure façon de montrer cette relation est montrée dans la figure II .1.




Figure II.1 : la relation entre deep learning et ML et IA.

Nous remarquons que l'apprentissage en profondeur est une branche spéciale de l'apprentissage automatique et que l'apprentissage automatique est une branche spéciale de l'intelligence artificielle.

II.2.1. L'intelligence artificielle :

L'intelligence artificielle a été proposée pour la première fois par John McCarthy en 1956 lors de sa première conférence universitaire sur le sujet. L'idée de machines fonctionnant comme des êtres humains a commencé à être le centre de l'esprit des scientifiques et le mathématicien Alan Turing a introduit l'idée de savoir s'il est possible de faire en sorte que les machines aient la même capacité de penser et d'apprendre par elles-mêmes. Alan Turing a pu concrétiser ses hypothèses et ses questions en testant si «les machines peuvent penser»? , Après une série de tests (plus tard appelé Test de Turing), il s'avère qu'il est possible de permettre aux machines de penser et d'apprendre comme les humains. Le test de Turing utilise l'approche pragmatique pour être en mesure d'identifier si les machines peuvent réagir en tant qu'humains [30].

II.2.2. : L'apprentissage automatique :

Apprentissage automatique utilisant des techniques multidisciplinaires telles que les statistiques, l'algèbre linéaire, l'optimisation et l'informatique pour créer des systèmes automatisés capables de parcourir de grandes quantités d'enregistrements de données à grande vitesse , aussi rapide que de prendre des photos sans intervention humaine. L'apprentissage automatique est désormais un domaine incroyablement répandu, avec des applications allant de l'intelligence d'affaires à la sécurité intérieure [31]. On s'attend à ce que les scientifiques des données connaissent les différences entre l'apprentissage automatique supervisé et l'apprentissage automatique non supervisé, ainsi que la modélisation d'ensemble, qui utilise une combinaison de techniques d'approches, et l'apprentissage semi-supervisé, qui combine des approches supervisées et non supervisées [32].

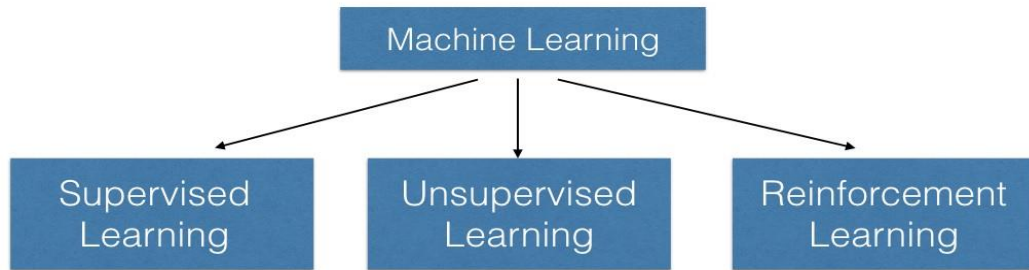


Figure II.2. : Méthodes d'apprentissage automatique.

II.2.3. L'apprentissage profond :

L'apprentissage profond est une forme d'apprentissage automatique qui peut utiliser des algorithmes supervisés ou non supervisés, ou les deux. Bien qu'il ne soit pas nécessairement nouveau, l'apprentissage en profondeur a récemment connu un regain de popularité en tant que moyen d'accélérer la résolution de certains types de problèmes informatiques difficiles, notamment dans les domaines de la vision par ordinateur et du traitement du langage naturel (PNL)[32].

Nous trouvons l'idée de base simple: de la même manière qu'un enfant entend les sons en premier, les connecte aux mots puis construit des phrases, les algorithmes d'apprentissage profond (neurones) vont progressivement recueillir et comprendre des informations pour créer de nouvelles connaissances. L'apprentissage profond se caractérise par mieux gérer les concepts abstraits, ce qui distingue de l'apprentissage automatique.

II.2.3.1. Méthodes d'apprentissage en profondeur :

Le processus d'apprentissage se déroule dans des algorithmes d'apprentissage profond de deux manières:

A)- Enseignement supervisé :

Lorsque l'apprentissage automatique est effectué sur la base d'un ensemble de données prédéfinies avec ses résultats corrects, comme la prévision des prix des logements après consultation d'un grand nombre de prix des logements voisins.

B)- Apprentissage non supervisé:

Lorsque l'apprentissage automatique est effectué à l'aide d'un ensemble de données mais sans reconnaissance préalable du résultat correct, comme le regroupement de points de

données dans des groupes spécifiques en fonction de modèles détectés automatiquement par l'algorithme).

II .2.3.2. Pourquoi d'apprentissage en profondeur?

La réponse à cette question est vraiment essentielle, elle nous permet de comprendre l'engouement autour du deep learning. Le graphe ci-dessus l'explique clairement.

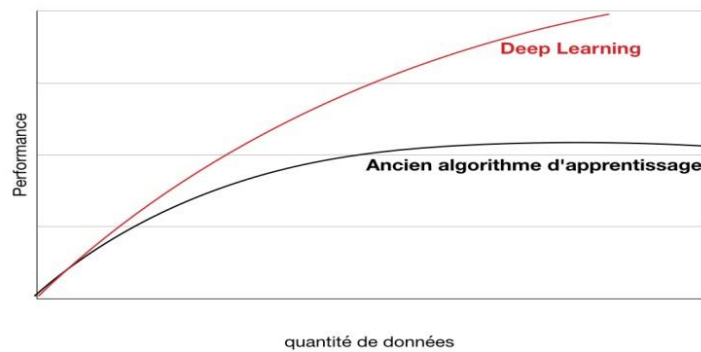


Figure II.3 : Qualité des données

Sa capacité à améliorer ses performances s'il y a une grande quantité de données (le passage à l'échelle) fait vraiment rêver vu que nous sommes à l'ère du big data et nous voulons exploiter au mieux nos données.

II.3. L'apprentissage profond et d'apprentissage automatique :

L'apprentissage profond est une forme spéciale d'apprentissage automatique. La progression de l'apprentissage automatique commence par (les fonctionnalités associées) qui sont extraites manuellement des images, puis les fonctionnalités sont utilisées pour créer un modèle qui classe les objets dans l'image. Avec le deep Learning, les fonctionnalités associées sont automatiquement extraites des images.




Figure II.4 : Une comparaison des étapes du fonctionnement des algorithmes DL et ML .

II.3.1. Fonctionnement des algorithmes d'apprentissage automatique ?

En termes simples, la plupart des algorithmes d'apprentissage automatique dépendent de leur apprentissage sur deux étapes de base: surveillance et simulation (prédiction) - c'est dans le groupe d'algorithmes qui dépendent de l'apprentissage supervisé, ou d'apprentissage en observant les événements précédents connus pour en résulter. Tout d'abord, il surveille les données d'entrée et tente de concevoir des modèles et des caractéristiques distincts de ces données, puis travaille à simuler le comportement des fonctions en fonction des liens et des relations qui ont été formés en surveillant le processus de conversion des données d'entrée en sorties spécifiques. Nous distinguons ici le terme algorithmes d'apprentissage automatique et modèles d'apprentissage automatique que les algorithmes signifient les étapes nécessaires et la méthode utilisée dans le processus d'apprentissage, tandis que le modèle symbolise une structure logicielle qui utilise l'un des algorithmes pour effectuer une tâche spécifique.

II.3.2. Algorithmes l'apprentissage profond:

Les algorithmes d'apprentissage profond consistent en un ensemble de processus non linéaires avec des structures profondes (d'où leur nom d'apprentissage profond). Ce qui distingue l'architecture de ces algorithmes, c'est qu'ils s'inspirent des réseaux de neurones du cerveau humain, c'est pourquoi les architectures d'apprentissage en profondeur sont appelées réseaux de neurones artificiels.

II.3.2.1. Les différents types Algorithmes d'apprentissage profond:

- réseaux neuronaux profonds.
- réseaux neuronaux convolutions.
- réseaux neuronaux récurrents.

II.4. Réseaux de neurones artificiels :

II.4.1. Définition:

Le cerveau humain se compose de centaines de milliards de cellules appelées neurones. Chaque neurone transmet des informations sous la forme d'un signal biologique électrique (impulsion nerveuse). Ces neurones sont donc les principaux éléments du système nerveux responsables des actions humaines. Lorsque le cerveau reçoit des informations, les neurones reçoivent des informations, les traitent, les transfèrent à d'autres neurones, etc. Ainsi, le réseau de neurones artificiels est un modèle mathématique inspiré graphiquement par le travail des neurones biologiques. Une composante des couches d'entrée de données et des couches de sortie de données et entre elles des couches d'analyse et de conclusion sont appelées couches cachées.

Les tâches particulièrement adaptées au traitement par réseau de neurones sont: l'association, la classification, la discrimination, la prévision ou l'estimation, et la commande de processus complexes [33].

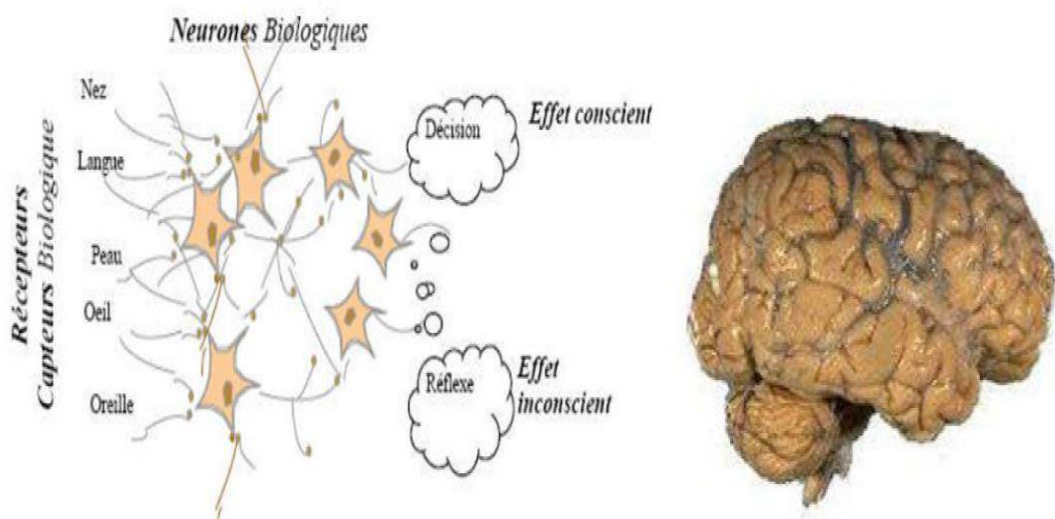


Figure II.5 : Structure d'un réseau de neurone biologique et le cerveau humain .

II.4.2. Comment ça marche un réseau de neurones ?

Un "neurone formel" (ou simplement "neurone") est une fonction algébrique non linéaire et bornée, dont la valeur dépend des paramètres appelés coefficients ou poids. Les variables de cette fonction sont habituellement appelées "entrées" du neurone, et la valeur de la fonction est appelée sa "sortie" [33].

Un neurone est donc avant tout un opérateur mathématique, dont on peut calculer la valeur numérique par quelques lignes de logiciel. On a pris l'habitude de représenter graphiquement un neurone comme indiqué sur la figure II.6.

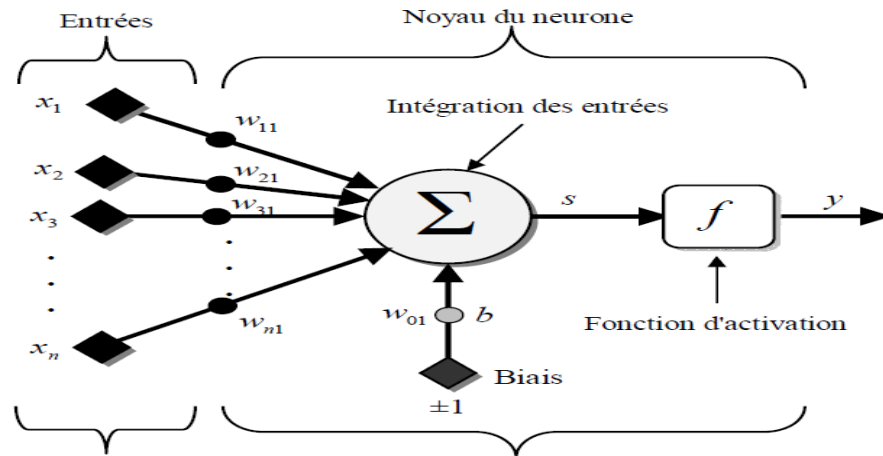


Figure II.6: Une explication simple du travail du réseau neuronal artificiel.

Des observations de neurone biologique, découle le modèle du neurone formel proposé par W.M. Culloch et W. Pitts en 1943[33] :

- Les x_i représentent les vecteurs d'entrées, elles proviennent soit des sorties d'autres neurones, soit de stimuli sensoriels (capteur visuel, sonore...).
- Les w_{ij} sont les poids synaptiques du neurone j . Ils correspondent à l'efficacité synaptique

dans les neurones biologiques ($w_{ij} > 0$: synapse excitatrice; $w_{ij} < 0$: synapse inhibitrice) ; Ces poids pondèrent les entrées et peuvent être modifiés par apprentissage.

- Biais : entrée prend souvent les valeurs -1 ou +1 qui permet d'ajouter de la flexibilité au réseau .

En permettant de varier le seuil de déclenchement du neurone par l'ajustement des poids et du

Biais lors de l'apprentissage.

- Noyau : intègre toutes les entrées et le biais et calcul la sortie du neurone selon une fonction

D'activation qui est souvent non linéaire pour donner une plus grande flexibilité d'apprentissage.

II.4.3. Les différents types de réseaux de neurones :

Généralement, il y a différents types de réseaux de neurones, et on cite les principaux:

- Feed-forward neural network (Autoencoder, Probabilistic neural network, Time Delay neural network, Convolutional neural network).
- Regulatory feedback network.
- Radial basis function network.
- Recurrent neural network.

II.5. Principes fondamentaux de l'apprentissage profond :

L'objectif principal des réseaux de neurones profonds est d'approximer des fonctions complexes grâce à une composition d'opérations simples et prédéfinies d'unités (ou neurones). Les opérations effectuées sont généralement définies par une combinaison pondérée d'un groupe spécifique d'unités cachées avec une fonction d'activation non linéaire, en fonction de la structure du modèle. Ces opérations ainsi que les unités de sortie sont appelées «couches». L'architecture du réseau neuronal ressemble au processus de perception dans un cerveau, où un ensemble spécifique d'unités est activé compte tenu de l'environnement actuel, influençant la sortie du modèle de réseau neuronal[2].

II.6. Propagation avant et arrière :

En termes mathématiques, l'architecture des réseaux de neurones profonds est généralement différentiable, donc les poids (ou paramètres) du modèle peuvent être appris en minimisant une fonction de perte en utilisant des méthodes de descente de gradient par rétro-propagation, en suivant la règle fondamentale de la chaîne [34]. Nous illustrons les principes des processus d'apprentissage et d'inférence d'un réseau neuronal profond dans la figure II.7, où nous utilisons un réseau neuronal convolutif bidimensionnel (CNN) Inputs x comme exemple[2].

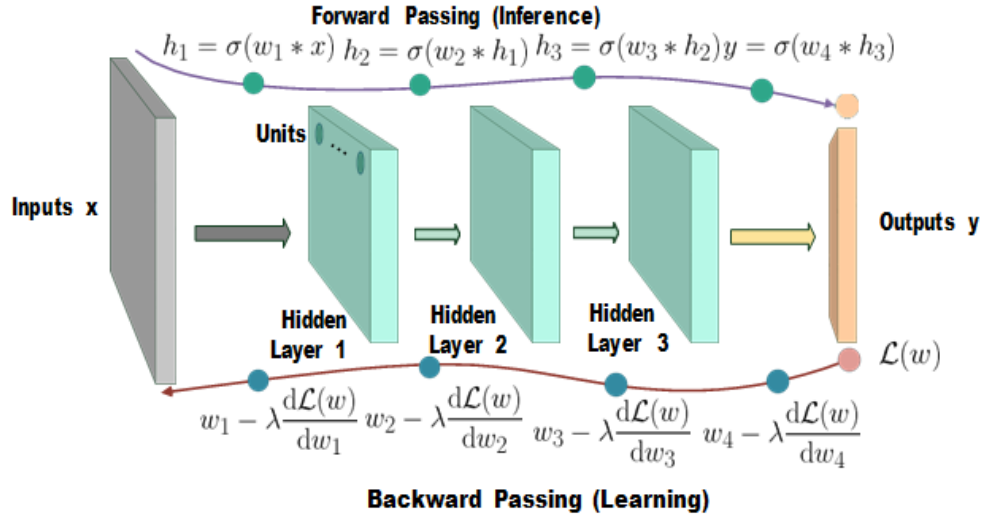


Figure II.7 : Illustration des processus d'apprentissage et d'inférence d'un CNN à 4 couches. $w(.)$ désigne les poids de chaque couche cachée, $\sigma(.)$ est une fonction d'activation, λ désigne le taux d'apprentissage, $\mathcal{L}(w)$ désigne l'opération de convolution et $\mathcal{L}(.)$ est la perte.

Propagation directe: La figure montre un CNN avec 5 couches, c'est-à-dire une couche d'entrée (gris), 3 couches cachées (bleu) et une couche de sortie (orange). En propagation directe, une entrée 2D x (par exemple des images) est d'abord traitée par une couche convolutive, qui effectue l'opération convolutionnelle suivante:

$$h_1 = \sigma(W_1 * x) \tag{II.1}$$

Ici h_1 est la sortie $h_1 = \sigma(W_1 * x)$ ie de la première couche cachée, W_1 est le filtre convolutionnel et $\sigma(.)$ est la fonction d'activation, visant à améliorer la non-linéarité et la représentabilité du modèle. La sortie h_1 est ensuite fournie en entrée et traitée par les deux couches convolutives suivantes, ce qui produit finalement une sortie finale y . Cela pourrait être par exemple un vecteur de probabilités pour différents motifs (formes) possibles découverts dans l'entrée (image).

Pour former le CNN de manière appropriée, on utilise une fonction de perte $L(w)$ pour mesurer la distance entre la sortie y et la vérité du sol y^* . Le but de la formation est de trouver les meilleurs poids w , afin de minimiser la fonction de perte $L(w)$. Ceci peut être réalisé par la propagation arrière par descente de gradient.

Propagation vers l'arrière: Pendant la propagation vers l'arrière, on calcule le gradient de la fonction de perte $L(w)$ sur le poids de la dernière couche cachée, et met à jour le poids en calculant:

$$W_4 = W_4 - \lambda \frac{dl(W)}{dW} \quad (\text{II.2})$$

Ici, λ désigne le taux d'apprentissage, qui contrôle la taille du pas de déplacement dans la direction indiquée par le gradient. La même opération est effectuée pour chaque poids, en suivant la règle de la chaîne. Le processus est répété et, éventuellement, la descente du gradient conduira à un ensemble w qui minimise le $L(w)$. Pour les autres structures NN, les processus de formation et d'inférence sont similaires [2].

II.7.Exemples de domaines d'application :

Le deep learning peut être appliqué en différent et nombreux domaine tel que :

- ✓ Contrôle vocal d'appareils tels que téléphones, téléviseurs et amplificateurs.
- ✓ Effectuer des tâches de classification directement à partir de la voix, de l'image ou du texte.
- ✓ Conduite conventionnelle, les chercheurs automobiles utilisent l'apprentissage en profondeur pour détecter des éléments tels que les panneaux de stationnement et les feux de circulation. En plus de cela, l'apprentissage en profondeur est utilisé pour détecter les piétons, ce qui contribue à réduire les accidents.
- ✓ L'espace et la défense sont utilisés pour identifier les objets des satellites qui définissent les zones d'importance et pour définir les zones sûres et dangereuses pour les forces militaires.
- ✓ Recherche médicale où les chercheurs sur le cancer utilisent l'apprentissage en profondeur pour dépister les cellules cancéreuses.
- ✓ L'industrie améliore la sécurité des travailleurs autour des machines lourdes en détectant les personnes ou les choses à une distance non sécurisée des machines.
- ✓ L'électronique dans la traduction automatique de l'audition et de la parole.
- ✓ Jeux et compétitions tels que trouver des solutions au jeu avec les mouvements les plus courts.

Donc et en bref , le deep learning est utilisé dans : le reconnaissance d'image, la traduction automatique, la voiture autonome, le diagnostic médical, les recommandations personnalisées, la modération automatique des réseaux sociaux, la prédiction financière et

trading automatisé, la détection de malwares ou de fraudes, les chatbots (agents conversationnels), l'exploration spatiale, et les robots intelligents.

II.8.Activation de l'apprentissage profond dans les réseaux 5G :

Le deep learning est de plus en plus utilisé dans de nombreux domaines, et la chose la plus importante que nous étudions est l'intégration du deep learning dans les réseaux mobiles. Et comme nous l'avons mentionné au chapitre 1, les systèmes 5G s'efforcent de fournir des services de communication à haut débit et une latence très faible pour améliorer la qualité de service pour les utilisateurs. Ce qui est l'un des objectifs les plus importants de l'application de l'apprentissage en profondeur .

La mise en œuvre de l'apprentissage en profondeur pour intégrer l'intelligence dans les systèmes 5G, afin d'atteindre ces objectifs, est coûteuse. En effet, du matériel et des logiciels puissants sont nécessaires pour prendre en charge la formation et l'inférence dans des contextes complexes. Heureusement, plusieurs outils voient le jour, qui rendent tangible l'apprentissage profond dans les réseaux mobiles ; à savoir [2] :

1. informatique parallèle avancée.
2. des systèmes d'apprentissage automatique distribués.
3. des bibliothèques dédiées au deep learning.
4. des algorithmes d'optimisation rapide.
5. calcul du brouillard , comme le montre la figure.

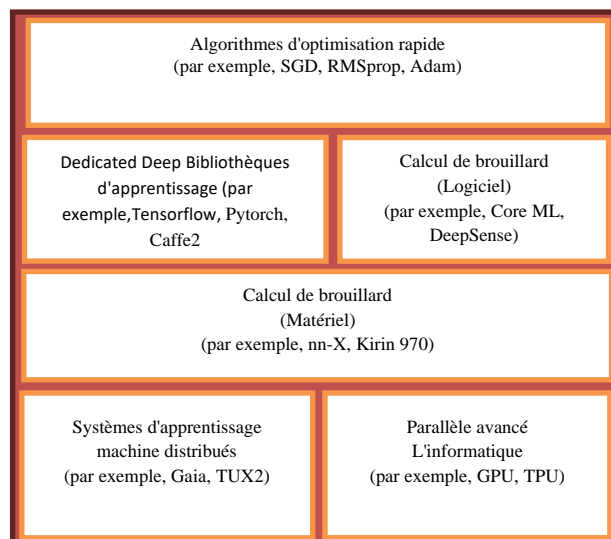


Figure II.8 : Une présentation hiérarchique des facteurs qui permettent à l'apprentissage profond d'être largement déployé dans le système de réseau mobile.

Ces outils peuvent être vus comme formant une structure hiérarchique, comme illustré sur la Figure II.8 ; il existe des synergies entre eux qui rendent les problèmes de réseau accessibles à des solutions basées sur l'apprentissage en profondeur. En utilisant ces outils, une fois la formation terminée, des inférences peuvent être faites dans des délais de la milliseconde. Nous résumons ces progrès dans le tableau II.1 [2].

II.8.1. Progression de l'apprentissage profond dans les systèmes mobiles :

Résumé des outils et techniques permettant la diffusion de l'apprentissage en profondeur dans les systèmes mobiles [2] :

Technique	Exemples	Portée	Fonctionnalité	Performance amélioration	Consommation d'énergie	Économique Coût
Avancée parallèle l'informatique	GPU, TPU [114] CUDA [115], cuDNN [116]	Serveurs mobiles, postes de travail	Activer rapide, parallèle formation / inférence de profonde modèles d'apprentissage sur mobile applications	Élevé	Élevé	Moyen (Matériel)
Dédié profond bibliothèque d'apprentissage	TensorFlow [117] Theano [118], Caffe [119], Torche [120]	Serveurs mobiles et appareils	Boîtes à outils de haut niveau permettre aux ingénieurs réseau de construire profonde spécifique à un but architectures d'apprentissage	Moyen	Associé avec Matériel	Faible (Logiciel)
Calcul du brouillard	nn-X [121], ncnn[122], Kirin 970 [123], Core ML [124]	Appareils mobiles Prise en charge	Appareils mobiles Prise en charge profonde en bordure apprentissage de l'informatique	Moyen	Faible	Moyen (Matériel)
Algorithmes d'optimisation rapide	Nesterov [125], Adagrad [126], RMSprop, Adam [127]	Former des architectures	Accélérez et stabilisez le processus d'optimisation de modèle	Moyen	Moyen associé au matériel	Faible (Logiciel)
Systèmes d'apprentissage machine distribués	MLbase [128], Gaia [10], Tux2 [11], Adam [129], GeePS [130]	Données distribuées centres, multi-serveur	Soutenir l'apprentissage en profondeur cadres dans mobile systèmes dans les centres de donnée	Élevé	Élevé	Élevé (matériel)

Tableau II.1 : Résumé des outils et techniques permettant de déployer le deep Learning dans les systèmes mobiles.

II.9. Apprentissage profond alimenté par des réseaux mobiles et sans fil :

Le deep learning a une large gamme d'applications dans les réseaux mobiles et sans fil. Le deep learning a fait des progrès spécifiques, parmi ces domaines[2]:

- Analyse des données mobiles au niveau du réseau grâce à l'apprentissage en profondeur.
- Analyse des données mobiles au niveau de l'application.
- Analyse approfondie des mouvements des utilisateurs.
- Localisation des utilisateurs dans le deep learning.
- Réseaux de capteurs sans fil pilotés par le deep learning.
- Contrôle de réseau d'apprentissage en profondeur.
- Sécurité réseau basée sur le Deep Learning.
- Traitement du signal par apprentissage profond.
- Application de réseau mobile d'apprentissage en profondeur émergente émergente.

II.10. Avantages du Deep Learning dans les réseaux mobiles et sans fil :

Nous reconnaissons plusieurs avantages de l'utilisation de l'apprentissage en profondeur pour résoudre les problèmes d'ingénierie réseau, comme le résume le tableau II.2. Plus précisément[2]:

- L'un des principaux avantages de l'apprentissage en profondeur est qu'il peut extraire automatiquement des fonctionnalités de haut niveau à partir de données présentant une structure complexe et des corrélations internes. Le processus d'apprentissage n'a pas besoin d'être conçu par un humain, ce qui simplifie énormément la fabrication artisanale des fonctionnalités antérieures .
- Deuxièmement, le deep learning est capable de gérer de grandes quantités de données. Les réseaux mobiles génèrent des volumes élevés de différents types de données à un rythme rapide.
- L'apprentissage profond fournit une variété de méthodes qui permettent d'exploiter des données non étiquetées pour apprendre des modèles utiles d'une manière non supervisée.

Aspect principal	La description	Avantages
Extraction de caractéristiques	Les réseaux de neurones profonds peuvent extraire automatiquement des fonctionnalités de haut niveau à travers des couches de différentes profondeurs.	Réduisez l'ingénierie des fonctions artisanales coûteuses dans le traitement de Big Data mobiles hétérogènes et bruyants.
Exploitation du Big Data	Contrairement aux outils ML traditionnels, les performances de l'apprentissage en profondeur augmentent généralement de manière significative avec la taille des données d'entraînement.	Utilisez efficacement d'énormes quantités de données mobiles générées à des taux élevés.
Apprentissage non supervisé	Le Deep Learning est efficace pour traiter les données non /semi-étiquetées, permettant un apprentissage non supervisé.	Traitement de grandes quantités de données non étiquetées, qui sont courantes dans les systèmes mobiles.
Apprentissage multi-tâches	Les fonctionnalités apprises par les réseaux de neurones via des couches cachées peuvent être appliquées à différentes tâches par apprentissage par transfert.	Réduisez les besoins en calcul et en mémoire lors de l'exécution de l'apprentissage multi-tâches dans les systèmes mobiles.
Apprentissage des données mobiles géométriques	Des architectures dédiées d'apprentissage en profondeur existent pour modéliser des données mobiles géométriques.	Révolutionnez l'analyse des données mobiles géométriques.

Tableau II.2: Résumé des avantages de l'application de l'apprentissage en profondeur pour résoudre les problèmes des réseaux mobiles et sans fil.

II.11. Limitations de l'apprentissage profond dans les réseaux mobiles et sans fil :

Bien que l'apprentissage en profondeur présente des avantages uniques lorsqu'il s'agit de le gérer, les problèmes de réseau mobile présentent également de nombreuses lacunes, qui limitent en partie l'applicabilité de l'apprentissage dans ce domaine. Précisément[2] :

1)- Malgré la supériorité des techniques d'apprentissage en profondeur dans de nombreux domaines, il est facile de tromper le système d'intelligence artificielle en général et l'apprentissage en profondeur en particulier intentionnellement ou automatiquement.

2)- Bien que le deep learning permette la création de «machines» très précises pour des tâches spécifiques, nous avons encore une connaissance limitée des raisons pour lesquelles les NNs prennent certaines décisions. Cela limite l'applicabilité de l'apprentissage en profondeur

3)- L'apprentissage en profondeur dépend fortement des données, qui peuvent parfois être plus importantes que le modèle lui-même. Les modèles profonds peuvent également bénéficier de données d'entraînement accrues [35]. C'est en effet une opportunité pour les réseaux mobiles, car les réseaux génèrent d'énormes quantités de données. Cependant, la collecte de données peut être coûteuse, confrontée à des problèmes de confidentialité, et il peut donc être difficile d'obtenir suffisamment d'informations pour la formation du modèle.

Cependant, cela reste cher. Pour contourner certains des problèmes ci-dessus et permettre un déploiement efficace dans les réseaux mobiles, l'apprentissage en profondeur nécessite une prise en charge spécifique du système et du programme[2].

II.12. Conclusion :

L'apprentissage profond est en fait une application croissante de l'apprentissage automatique. Les nombreuses applications décrites dans le présent chapitre démontrent son développement rapide en seulement quelques années. L'utilisation de différents algorithmes efficaces apparaît dans une variété de domaines. La principale valeur de l'apprentissage en profondeur est basée sur l'amélioration des applications actuelles dans l'apprentissage automatique, en raison de sa nature innovante de traitement de couche hiérarchique.

Nous notons également que les pratiques actuelles d'apprentissage en profondeur dans les réseaux mobiles utilisent largement l'apprentissage supervisé et l'apprentissage amélioré. Cependant, étant donné que les réseaux mobiles génèrent quotidiennement de grandes

Chapitre II : Deep Learning (l'apprentissage en profondeur)

quantités de données non classifiées, la catégorisation des données est coûteuse et nécessite des connaissances spécifiques au domaine. Pour faciliter l'analyse des données primaires du réseau mobile, un apprentissage non censuré devient nécessaire pour extraire des idées de données non classifiées, afin d'améliorer la fonctionnalité du réseau mobile pour améliorer la qualité de service.

Chapitre III :
Exemples, résultats et discussions

III.1. Introduction :

Comme nous avons vu dans les précédents chapitres que l'application de l'apprentissage en profondeur connu sous deep-learning représente un défi massif pour les systèmes multi-antennes de la 5G. Le deep-learning peut résoudre efficacement plusieurs problèmes comme l'estimation de canal, l'atténuation de la contamination des pilotes, le codage de source et de canal, le Beamforming ... etc. Le présent chapitre va montrer trois importantes applications du deep-learning qui représentent des exemples sur des travaux récemment publiés sur la littérature de recherche. Nous allons essayer d'expliquer la méthode proposée dans chacun des travaux et nous allons aussi discuter leurs résultats obtenus.

III.2.Exemple 1: Deep learning pour l'allocation de puissance dans un système MIMO massif :

Dans cet exemple nous allons voir l'utilisation du deep learning pour résoudre les problèmes d'allocation de puissance max-min et max-prod dans la liaison descendante (DL) des réseaux MIMO massif. Les auteurs de l'article [36] ont proposé un réseau neuronal profond qui est formé pour apprendre le plan (la carte) entre les positions des équipements utilisateur (UE) et les politiques d'allocation de puissance optimales, ensuite ce réseau est utilisé pour prédire le profil d'allocation de puissance pour un nouvel ensemble de positions des utilisateurs.

III.2.1. Allocation de puissance:

L'efficacité spectrale descendante de l'utilisateur k dans la cellule j peut être écrite comme suit :

$$\text{Ou : } SE_{jk}^{dl} = \frac{T_d}{T_c} \log_2 \left(1 + \frac{\rho_{jk} \alpha_{jk}}{\sum_{l=1}^L \sum_{i=1}^K \rho_{li} b_{lijk} + \sigma^2} \right) \quad \forall j, k \quad (\text{III.1})$$

$$\alpha_{jk} = \left| \mathbb{E} \left\{ w_{jk}^H h_{jk}^j \right\} \right|^2 \quad (\text{III.2})$$

$$\text{Et : } b_{lijk} = \begin{cases} \mathbb{E} \left\{ \left| w_{jk}^H h_{jk}^l \right|^2 \right\} & (l, i) \neq (j, k) \\ \mathbb{E} \left\{ \left| w_{jk}^H h_{jk}^l \right|^2 \right\} - \left| \mathbb{E} \left\{ w_{jk}^H h_{jk}^l \right\} \right|^2 & (l, i) = (j, k) \end{cases} \quad (\text{III.3})$$

Sont les moyennes du gain de canal et du gain d'interférences, respectivement. La moyenne est calculée par rapport aux réalisations d'évanouissements à petite échelle de sorte que

l'efficacité spectrale descendante ne soit fonction que des statistiques d'évanouissements à grande échelle et du choix du pré codage.

Parmi les différentes politiques d'allocation de puissance, deux exemples notables sont les stratégies d'équité max-min et SINR max Product (max-prod), qui peuvent être formalisées mathématiquement comme suit :

$$\max_{\{\rho_{jk}; \forall j,k\}} , \quad \min_{j,k} SE_{jk}^{dl} \quad (III.4)$$

$$\text{Sous la contrainte : } \sum_{k=1}^k \rho_{jk} \leq P_{\max}^{dl}, j = 1, \dots, L$$

$$\text{Et le produit maximal SINR, donné par : } \max_{\{\rho_{jk}; \forall j,k\}} \prod_{j=1}^L \prod_{k=1}^K \gamma_{jk}^{dl} \quad (III.5)$$

$$\text{Sous la contrainte : } \sum_{k=1}^k \rho_{jk} \leq P_{\max}^{dl}, j = 1, \dots, L$$

Où P_{\max}^{dl} désigne la puissance descendante d'émission maximale. Quelle que soit la stratégie, la méthodologie de Monte Carlo suivante est nécessaire pour calculer les puissances optimales :

- Effets de propagation macroscopique.
- Effets de propagation microscopique.
- Calcul efficacité spectrale (SE).
- Allocation de puissance en résolvant les équations (III.4) et (III.5).

La solution de (III.4) peut être obtenue par une approche de bisection dans laquelle une séquence de problèmes convexes est résolue, tandis que (III.5) peut être résolu par programmation géométrique. Ainsi, à la fois (III.4) et (III.5) nécessitent une complexité polynomiale ou quasi-polynomiale pour être résolus. Cependant, même une complexité polynomiale peut être trop importante lorsque la solution doit être obtenue en temps réel; c'est-à-dire suffisamment rapide pour être déployé dans le système avant que les positions des UE ne changent et que le problème d'allocation de puissance doive être à nouveau résolu.

III.2.2. Allocation de puissance basée sur l'apprentissage profond :

L'objectif central de ce travail est de démontrer que es informations de localisation des équipements utilisateurs sont déjà suffisantes comme proxy pour calculer les puissances optimales à n'importe quelle cellule donnée. Ceci contraste avec les approches

d'optimisation traditionnelles pour la résolution (III.4) et (III.5) qui nécessitent la connaissance de $\{a_{jk}\}$ et de $\{b_{lijk}\}$ dans (III.2) et (III.3).

Nous préconisons d'utiliser les positions des équipements utilisateurs car elles capturent déjà la caractéristique principale des canaux de propagation et des interférences dans le réseau. Par conséquent, pour toute cellule j donnée, le problème est d'apprendre la carte inconnue entre la solution $\rho_j^* = [\rho_{j1}^*, \dots, \rho_{jK}^*] \in \mathbb{R}^K$ à (III.4) ou (III.5) et les $2KL$ positions géographiques des équipements utilisateurs. $X = \{X_{li}^j; \forall j, l, i\} \in \mathbb{R}^{2KL}$ Ceci est réalisé en tirant parti de la propriété connue des réseaux neuronaux qui sont des approximateurs de fonction universels. En particulier, nous utilisons un réseau de neurones à anticipation (feedforward) avec des couches entièrement connectées, et composé d'une couche d'entrée de dimension $2KL$, de N couches cachées et d'une couche de sortie de dimension $K + 1$ donnant une estimation $\hat{\rho} = [\hat{\rho}_{j1}, \dots, \hat{\rho}_{jK}]$ du vecteur d'allocation de puissance optimal ρ_j^* .

On remarque que la couche de sortie a une taille $K + 1$ au lieu de K , puisque nous faisons également apprendre au NN $\sum_{k=1}^K \rho_{jk}^*$ afin de satisfaire la contrainte de puissance et d'augmenter la précision d'estimation.

III.2.3. Evaluation des performances :

Pour la simulation, on considère un réseau MIMO massif avec $L = 4$ cellules, chaque cellule couvrant une surface carrée de $2K = 550 \times 250$ m. Une topologie enveloppante est utilisée. On suppose un que $K = 5$ utilisateurs sont distribués aléatoirement et uniformément dans chaque cellule, à des distances supérieures à 35 m de la station de base (BS). Les résultats sont en moyenne sur 100 distributions d'utilisateur. On considère que la communication est sur une bande passante de 20 MHz avec une puissance de bruit totale du récepteur ρ^2 de -94 dBm. On suppose aussi que $T_p = K$; (c'est-à-dire, facteur de réutilisation pilote de 1) et que la puissance d'émission montante par utilisateur est de 20 dBm.

	Taille	Paramètres	Activation fonction
Entrée	40	-	-
Couche 1(dense)	64	2624	Elu
Couche 2(dense)	32	2080	Elu
Couche 3(dense)	32	1056	Elu
Couche 4(dense)	32	528	Elu
Couche 5(dense)	5	85	Elu
Couche 6(dense)	6	36	Linéaire

Tableau III.4: Disposition du réseau neuronal. Les paramètres entraîables sont 6,373.


Les réseaux de neurone ont été formés sur la base d'un ensemble de données $N_T = 340000$ échantillons de réalisations indépendantes des positions des équipements utilisateurs (UE), $\{X(n); n = 1, \dots, N_T\}$ pour $j = 1, \dots, L$ obtenu en résolvant (III.4) et (III.5) avec approches d'optimisation traditionnelle. En particulier, 90% des échantillons ont été utilisés pour la formation et 10% pour la validation. D'autres 10000 échantillons ont formé l'ensemble de données de test, qui est indépendant du jeu de données d'entraînement. On a utilisé l'optimiseur Adam, et on a choisi le MSE relatif comme fonction de perte $\ell(.,.)$ car les résultats numériques ont montré qu'il fonctionnait mieux que le MSE pour le problème en question. Le taux d'apprentissage, la taille des lots et les époques ont été ajustés avec une approche par essais et erreurs.

III.2.3.1.Max-prod :


Pour évaluer les performances de l'allocation de puissance basée sur réseau neuronal, on illustre la fonction de distribution cumulative (CDF) de l'efficacité spectrale descendante (DL SE) par équipement utilisateur (UE). On considère le MR et le M-MMSE. Le Réseau de neurone (NN) utilisé avec les deux schémas de précodage est indiqué dans le tableau III.5, dont les paramètres d'apprentissage sont 6, 373.

Les résultats de la Figure. III.1 (a) montrent que le NN correspond très bien à la solution optimale avec M-MMSE. Le MSE moyen est de 0: 007. Avec le précodage MR, on observe un petit décalage entre les deux courbes. En effet, l'erreur quadratique moyenne (MSE) augmente à 0.051. Figure. III.1 (b) illustre le CDF du MSE des efficacités spectrales SE. Comme prévu, la courbe CDF avec M-MMSE est à gauche de la courbe MR. Cela signifie essentiellement que le NN atteint, statistiquement parlant, de meilleures performances avec M-MMSE qu'avec MR.

Pour améliorer les capacités d'apprentissage avec MR, on a également considéré le NN plus complexe rapporté dans le tableau III.2. Les résultats numériques montrent que le MSE moyen des SE diminue à 0.003 et 0.015 avec le précodage M-MMSE et MR, respectivement.



(a) CDF of the DL SE per UE



(b) CDF of the MSE of SEs

Figure III.1: CDF de l'efficacité spectrale descendante et du MSE des efficacités spectrales avec précodages MR et M-MMSE en utilisant le réseau de neurone du tableau III.6.

	Taille	Paramètres	Activation fonction
Entrée	40	-	-
Couche 1(LSTM)	256	204128	Relu
Couche 2(LSTM)	128	197120	Relu
Couche 3(dense)	64	8256	Relu
Couche 4(dense)	5	325	Relu

Tableau III.2: Disposition pour une cellule donnée avec L = 4 et K = 5. Paramètres entraînaables:509,829.

Ceci est réalisé au prix d'une complexité de calcul et d'un temps d'apprentissage puisque le nombre de paramètres entraînaables est de 202, 373, au lieu de 6, 373.

Pour conclure, avec la stratégie max-prod, l'allocation de puissance basée sur l'apprentissage en profondeur proposée présente un avantage de complexité de calcul significatif par rapport aux approches traditionnelles, tout en maintenant des performances quasi optimales avec le précodage MR et M-MMSE.

III.2.3.2.Max-min :

Les réseaux de neurone (NN) utilisés pour la stratégie max-prod, se sont révélés inadéquats avec l'approche max-min. Ceci est probablement dû au fait que la distribution de puissance change considérablement entre les deux stratégies.

	Taille	Paramètres	Activation fonction
Entrée	40	-	-
Couche 1(LSTM)	256	204128	tanh
Couche 2(LSTM)	128	197120	tanh
Couche 3(dense)	64	8256	Relu
Couche 4(dense)	5	325	Relu

Tableau III.3: Disposition pour une cellule donnée avec L = 4 et K = 5; Paramètres entraînaables:509,829.




Figure III.2: CDF de l'efficacité spectrale descendante avec précodages MR et M-MMSE en utilisant le réseau de neurone du tableau III.2.

Un réseau de neurones (NN) se compose de deux couches répétées de mémoire à court terme (LSTM) et de deux couches denses. Les paramètres NN ainsi que les fonctions d'activation sont résumés dans le tableau III.3.

Les résultats de la figure III.2 montrent que le réseau de neurone NN correspond presque

exactement aux courbes théoriques avec MR et M-MMSE. Malgré des résultats satisfaisants en termes de précision, le NN du tableau III.3 compte un nombre total de 509, 829 paramètres entraînaables. C'est un nombre relativement élevé pour un réseau MIMO Massif avec $L = 4$ et $CN(0, \sigma^2)$ $K = 5$. Il manque d'évolutivité lorsque la taille du réseau augmente.

III.3. Exemple 2: Modèle d'apprentissage en profondeur orienté pour la suppression des brouillages dans les systèmes de connectivité massive :

Le travail présenté dans l'article [37] décrit une méthode pour séparer les signaux de collision de plusieurs utilisateurs en présence d'un signal d'interférence/brouillage fort et à large bande. Plus précisément, il considère une configuration de connectivité massive où peu, sur un grand nombre d'utilisateurs, équipés de codes d'étalement, transmettent des symboles de manière synchrone.

Le signal reçu est un mélange bruité de symboles transmis par les canaux à évanouissements plats des utilisateurs, altéré par un signal de brouillage à sauts de fréquence rapides d'une puissance relativement importante. Le travail propose une méthode d'apprentissage en profondeur pilotée, basée sur un réseau neuronal conventionnel, pour supprimer le signal de brouillage du signal reçu, et détecter les utilisateurs actifs ainsi que leurs symboles transmis.

III.3.1. Algorithme proposé :

Dans cette section, on décrit en bref l'algorithme proposé. Le signal reçu est traité à travers une cascade de deux blocs. Le but du premier bloc est de supprimer le signal de brouillage et de sortir un mélange propre de signaux transmis par les utilisateurs actifs. Ce mélange est alors une entrée du second bloc qui sort les indices des utilisateurs actifs, ainsi que leurs symboles détectés.

III.3.2. Suppression de brouillage basée sur la liaison descendante:

Le procédé de suppression de brouilleur est conçu en apprenant un modèle discriminatif qui mappe un signal reçu prétraité r au mélange souhaité de signaux d'utilisateurs actifs y . Pour guider la sélection d'un modèle de liaison descendante (DL), nous considérons le problème de suppression du brouilleur comme étant de nature analogue au problème de restauration d'image. Notre bloc de suppression de brouilleur implémente le modèle DL illustré à la figure III.3. Le modèle se compose de D couches dont les blocs de construction sont une sous-couche de convolution, activation d'unité linéaire rectifiée (ReLU) et

normalisation des lots. Plus spécifiquement, la première couche traite le signal d'entrée via une sous-couche de convolution, suivie de l'activation de ReLu. Chaque suivante couche d , $d=2, \dots, D-1$, utilise BN vers la sortie activée ReLu de la sous-couche de convolution correspondante. Finalement, une seule sous-couche de convolution est la couche de sortie dans le modèle DL proposé.




Figure III.3: Architecture DL pour la suppression des brouilleurs.

L'entrée de l'architecture DL proposée est un tenseur constitué de deux canaux, comme illustré sur la figure III.4. Le premier canal r est formaté en une matrice à deux colonnes qui contient des parties réelles et imaginaires du signal reçu r . Le deuxième canal \hat{r} est également formaté dans une matrice à deux colonnes, avec des parties réelles et imaginaires de la sortie r_{MFB} d'un banc de filtres adaptés (MFB: match filter bank) dans ses colonnes. En particulier, le signal reçu r est traité à travers le MFB constitué de S filtres, chacun accordé sur une séquence d'étalement $S_j, j = 1, \dots, S$.

$$r_{MFB} = S^H r \quad (III.6)$$

Nous rappelons que la première couche de convolution calcule la combinaison pondérée des entrées voisines dans le tenseur sur un patch dont la dimension est donnée par la taille du noyau de convolution. En particulier, les entrées de la i ème ligne du premier canal correspondent aux i ème échantillons de chip du signal reçu, tandis que la i ème ligne du deuxième canal est la somme bruyante du symbole transmis par l'utilisateur i et la combinaison pondérée des échantillons de débit binaire du signal de brouillage, les poids

étant les entrées du code d'étalement s_j . Ainsi, la première couche de convolution combine plusieurs échantillons consécutifs du signal de bruit et les combinaisons pondérées de l'ensemble du signal de brouillage, ainsi que le même nombre d'échantillons consécutifs du mélange des signaux des utilisateurs actifs et des symboles transmis par les utilisateurs actifs. Les couches de convolution restantes calculent les combinaisons pondérées d'entrées à partir de leurs tenseurs d'entrée, de sorte que le modèle entier combine des informations "locales", représentant des échantillons consécutifs du signal utile y et du signal de bruit z , avec les informations "globales", comprenant les symboles transmis x_j , et signal de brouillage projetés sur des codes d'étalement, $S_j^H z$ dans le but de supprimer le signal de brouillage z et de produire le mélange de signaux d'utilisateurs actifs y .




Figure III.4: L'entrée du tenseur dans le modèle DL.

Après avoir spécifié l'architecture DL, ses poids w sont estimés en minimisant la norme au

$$\text{carré } l_2 \text{ de l'erreur, } \hat{W} = \arg \min_w \sum_{k=1}^K \|y_k - \mathfrak{R}(r_k; w)\|^2 \quad (\text{III.7})$$

Où K est le nombre d'exemples d'apprentissage (r_k, y_k) , tandis que $\mathfrak{R}(\cdot, w)$ désigne le mappage du signal reçu r à la sortie DL, paramétré par les poids w .

III.3.3. Détection de symboles :

La récupération des utilisateurs actifs et des symboles transmis est décrite dans cette partie. La sortie du bloc de suppression de brouilleur est d'abord mappée en un signal de domaine complexe $\tilde{y} \in \mathbb{C}^{S \times 1}$. En supposant que la suppression du brouilleur ne déforme pas le

mélange des signaux des utilisateurs transmis, la sortie \tilde{y} est donnée par :

$$\tilde{y} = \tilde{H} S \tilde{b} + \tilde{V} \quad (\text{III.8})$$

Où \tilde{H} est une matrice diagonale des magnitudes des canaux utilisateurs; c'est-à-dire $\tilde{H} = \text{diag}(|h_1|, |h_2|, \dots, |h_N|)$, tandis que \tilde{b} est un vecteur de symboles transmis. où S est le facteur d'étalement.

Où \tilde{V} modélise le signal de brouillage résiduel (non supprimé) et le bruit. Le problème de la détection des utilisateurs actifs et de leurs symboles transmis à partir de (III.8) est essentiellement un problème de récupération clairsemé car seuls quelques utilisateurs transmettent en même temps, ce qui entraîne un vecteur clairsemé de leurs symboles \tilde{b} .

Nous utilisons ici l'algorithme de décorrélation de dimension réduite (RDD) pour détecter \tilde{b} à partir de (III.8). Le RDD est une méthode simple de détection de symboles en un seul coup qui met en corrélation \tilde{y} avec chaque code d'étalement S_i pour générer des t_i statistiques correspondant au i ème utilisateur. En supposant que le nombre d'utilisateurs actifs K est connu (c'est-à-dire obtenu par un autre algorithme), le RDD détecte les utilisateurs actifs à partir des indices de K plus grandes magnitudes $\{t_i\}_{i=1}^N$.

Enfin, le RDD détecte le symbole transmis d'un utilisateur actif en trouvant le symbole de constellation le plus proche au sens Euclidien de t_i . Notons que lorsque les codes d'étalement sont orthogonaux, le RDD devient un banc de filtres adaptés conventionnel (MFB).

Pour finir, notre choix de l'algorithme RDD est motivé par sa simplicité et le fait que l'objet de ce travail est la suppression du signal de brouillage. Par conséquent, le RDD ne limite pas la généralité de la méthodologie proposée et d'autres algorithmes de récupération clairsemés peuvent être utilisés pour détecter \tilde{b} à partir de \tilde{y} .

III.3.4. Etude de simulation :

L'architecture DL de la figure III.3 implémente $D = 5$ couches. Chaque sous-couche de convolution comprend 32 filtres de convolution ; (c'est-à-dire, donne 32 cartes de caractéristiques), à l'exception de la dernière couche qui implémente un seul filtre de convolution. Le noyau de convolution dans chaque couche couvre 5 lignes consécutives et

les deux colonnes ; (c'est-à-dire, a une dimension 5 par 2) et un remplissage nul est utilisé. Chaque canal du tenseur d'entrée est normalisé avec la puissance maximale du signal correspondant. Le processeur RDD se résume à un MFB conventionnel en raison de l'orthogonalité des codes d'étalement. En supposant que le nombre d'utilisateurs actifs soit connu, les sorties MFB sont utilisées pour détecter les indices d'utilisateurs actifs et leurs symboles QPSK transmis.

On a formé et testé l'architecture de la figure III.3 avec plus de couches et /ou 16, 64 ou 128 filtres de convolution par sous-couche, sans observer une performance considérablement améliorée. De plus, les tests avec des modèles où le BN est utilisé avant Relu montrent une détérioration des performances de $\sim 0,5\%$, par rapport au cas où le BN agit sur les activations ReLu, comme c'est le cas dans le modèle DL utilisé. On note que le modèle à 5 couches n'est pas aussi profond que les modèles où le BN a été initialement suggéré comme régularisateur. Cependant, les tests sans BN donnent des performances légèrement dégradées, raison pour laquelle on conserve BN dans notre modèle.

La dépendance du taux d'erreur sur la variance du bruit blanc additif gaussien (AWGN) pour un modèle formé pour puissance du signal bruité de 20 dB et la variance du bruit -10 dB par rapport au signal transmis d'un utilisateur actif est représentée sur la figure III.5. Comme on peut le voir, en comparaison avec le MFB conventionnel qui donne des taux d'erreur de $\sim 95\%$, les taux d'erreur de l'algorithme proposé sont d'environ 1% pour des variances AWGN plus petites et plus pratiques.

Dans le test suivant, la variance de bruit AWGN est fixée à -10 dB et la puissance du signal de brouillage est variée. Les performances de taux d'erreur qui en résultent, illustrées sur la figure III.6, confirment que l'algorithme proposé surpasse considérablement le MFB pour les brouilleurs plus puissants.




Figure III.5: Taux d'erreur en fonction de la variance de bruit AWGN pour un modèle formé pour une puissance de brouillage de 20 dB. Deux utilisateurs actifs.

La performance du taux d'erreur de l'algorithme proposé et de la référence MFB pour le balayage de puissance du brouilleur et le nombre différent d'utilisateurs actifs est illustrée à la Figure III.7. Le modèle DL sous-jacent est formé pour 5 utilisateurs actifs, la puissance du brouilleur est de 20 dB et la variance du bruit AWGN est -10 dB. On note que le test effectué dans un scénario d'un utilisateur actif ne produit aucune erreur sur 10 000 exécutions pour des puissances de brouilleur comprises entre 10 et 14 dB. Comme prévu, les performances du taux d'erreur se détériorent avec le nombre croissant d'utilisateurs.




Figure III.6: Taux d'erreur en fonction de la puissance du brouilleur pour un modèle formé pour une puissance de brouillage de 20 dB, la variance AWGN est -10 dB et deux utilisateurs actifs.

Cependant, même si le modèle est formé pour 5 utilisateurs actifs, les taux d'erreur sont inférieurs à 10% dans les scénarios avec jusqu'à trois utilisateurs actifs et pour la plupart des puissances de brouillage considérées.




Figure III.7: Taux d'erreur en fonction de la puissance du brouilleur pour un modèle formé pour une puissance de brouilleur de 20 dB, une variance AWGN de -10 dB et cinq utilisateurs actifs.

III.4. Exemple 3: Formation de faisceaux hybride pour MIMO à onde millimétrique: une approche d'apprentissage automatique :

Dans un travail proposé par [38], un réseau neuronal profond basé sur une formation de faisceaux hybride (HB : Hybrid Beamforming) pour le système MIMO massif multi-utilisateurs à onde millimétrique. Le système HB est formulé comme un réseau neuronal auto-encodeur, qui est formé dans un style d'apprentissage auto-supervisé de bout en bout. Grâce à la forte capacité de représentation du réseau neuronal profond, le modèle proposé présente des performances supérieures aux méthodes de traitement linéaire traditionnelles. Selon les résultats de la simulation, le DNHB surpasse environ 2 dB en termes de performances de taux d'erreur sur les bits (BER) par rapport aux méthodes existantes.

III.4.1. Modèle du système :

Un système MIMO massif multi-utilisateurs typique à onde millimétrique et à une seule cellule à bande étroite est illustré sur la figure III.8.

La station de base (BS) est équipée N_t antennes d'émission et de N_t^{rf} chaînes de radiofréquence (RF). Chaque chaîne RF sert K utilisateurs équipés par N_r antennes de réception et N_r^{rf} chaînes RF. Le nombre de trains (flux) de données indépendants est N_s , ce qui signifie que le total des données KN_s est traité par la station de base. Pour garantir

la qualité avec le nombre limité de chaînes RF, le nombre de flux transmis est contraint par $KN_s \leq N_t^{rf} \leq N_t$ pour la BS et $N_s \leq N_r^{rf} \leq N_r$ pour chaque utilisateur.

Au niveau de la station de base (BS), les symboles transmis sont supposés être traités par un $N_t^{rf} KN_s$ formateur de faisceau numérique F_D puis par un formateur de faisceau analogique F_A de dimension $N_t \times N_t^{rf}$ pour construire le signal émis final. Mathématiquement, le signal transmis peut être écrit comme :

$$X = F_s = F_A F_D S = \sum_{K=1}^K F_A F_{DK} S_k \quad (III.9)$$

Où $F = F_A F_D$ désigne la matrice HB avec $F_D = [F_{D1}, F_{D2}, \dots, F_{DK}]$, F_{DK} est une matrice de formation de faisceaux numérique pour $k=1,2,\dots,K$, et $S \in \mathbb{C}^{KN_s \times 1}$ est le vecteur de symboles de signal qui est la concaténation du vecteur de flux de données de chaque utilisateur tel que $S = [S_1^T, S_2^T, \dots, S_K^T]^T$, où S_k désigne le vecteur de flux de données pour l'utilisateur k. On suppose que $E[SS^H] = I_{KN_s}$. Pour l'utilisateur k, le signal reçu peut être modélisé par :

$$y_k = H_k F_A F_{DK} S_k + H_k \sum_{l \neq K} F_A F_{Dl} S_l + n_k \quad (III.10)$$

où $H_k \in \mathbb{C}^{N_r \times N_t}$ est la matrice de canal pour le k-ième utilisateur et $n_k \in \mathbb{C}^{N_s \times 1}$ est le vecteur CN $(0, \sigma^2)$ de bruit gaussien additif complexe.

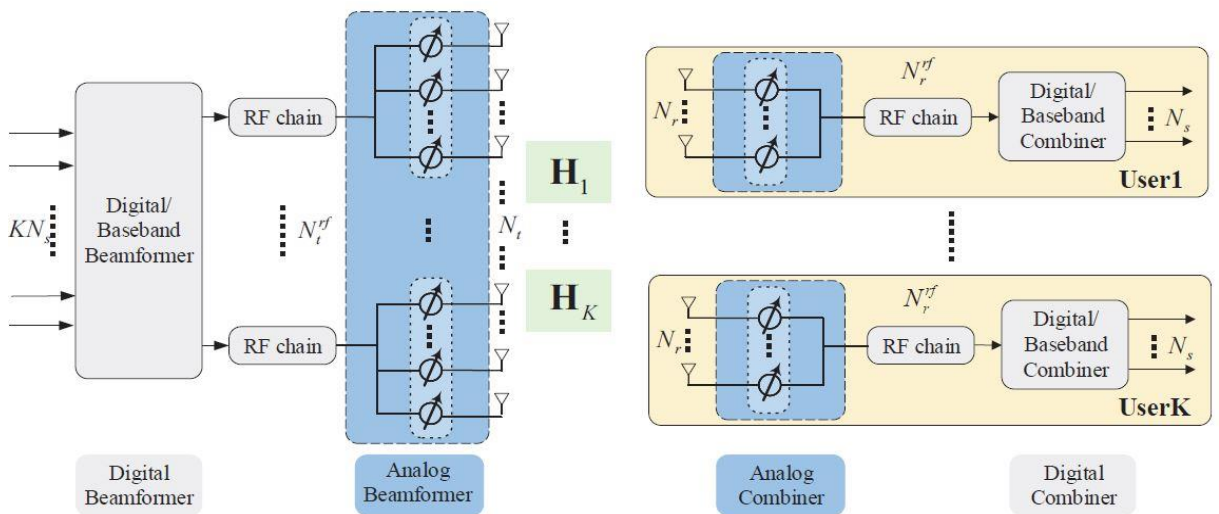


Figure III.8: Illustration d'un système MIMO massif de formation de faisceau hybride à cellule unique et bande étroite.

Le signal reçu après le formateur de faisceau au k-ième utilisateur est donné par:

$$\tilde{S}_k = \underbrace{W_{DK}^H W_{AK}^H H_K F_A F_{DK} S_K}_{\text{signaux souhaités}} + \underbrace{W_{DK}^H W_{AK}^H H_K \sum_{l \neq K} F_A F_{Dl} S_l}_{\text{interférence effective}} + \underbrace{W_{DK}^H W_{AK}^H n_K}_{\text{bruit efficace}} \quad (\text{III.11})$$

Où $W_{AK} \in \mathbb{C}^{N_r \times N_r^f}$ est la matrice de combinaison analogique et $W_{DK} \in \mathbb{C}^{N_r^f \times N_s}$ est la matrice de combinaison numérique pour le k-ième utilisateur. Puisque W_{AK} est également implémenté par les déphaseurs analogiques, tous les éléments de W_{AK} doivent avoir une amplitude constante telle que $|W_{AK}(i, j)|^2 = 1$. On suppose que les informations d'état de canal parfait (CSI) sont disponibles à la fois sur l'émetteur et récepteur et qu'il y a une synchronisation parfaite entre eux.

III.4.2. Formulation du problème :

On utilise somme de l'erreur quadratique moyenne (sum-MSE) [39][40], de tous les utilisateurs et de tous les flux comme mesure de performance et objectif d'optimisation pour la conception commune de transmission et de réception HB, qui est définie comme:

$$MSE \square \sum_{K=1}^K MSE_K = \sum_{K=1}^K E \left\{ \left\| S_K - \tilde{S}_K \right\|_F^2 \right\} \quad (\text{III.12})$$

Où MSE_k désigne le MSE du k-ième utilisateur. En remplaçant (III.11) par (III.12) et indépendamment de l'interférence effective, on obtient :

$$MSE \square \sum_{K=1}^K E \left\{ \left\| S_K - \left(W_{DK}^H W_{AK}^H H F_A F_{DK} S_K + W_{DK}^H W_{AK}^H n_K \right) \right\|_F^2 \right\} \quad (\text{III.13})$$

Enfin, le problème d'optimisation dans le scénario à bande étroite pour multi-utilisateur peut être formulé comme :

$$\underset{F_{DK}, F_A, W_{AK}^H, W_{DK}^H}{\text{minimize}} \sum_{K=1}^K MSE_K \quad (\text{III.14})$$

$$\begin{aligned} \text{tr} F_A F_D F_D^H F_A^H &\leq P, \\ |F_A(i, j)|^2 &= 1, \forall i, j, \\ |W_{AK}(i, j)|^2 &= 1, \forall i, j, K, \end{aligned}$$

Où P représente le bilan de puissance total à la station de base.

III.4.3.conception d'un beamformer hybride basée sur AE :

Le AE représente une sous-classe du réseau de neurones artificiels utilisé pour l'apprentissage non supervisé. Les auteurs de [38] ont proposé un réseau neuronal HB dont le schéma de principe matériel du système MIMO massif multi-utilisateur à onde millimétrique et cellule unique de liaison descendante illustré à la Figure III.9.

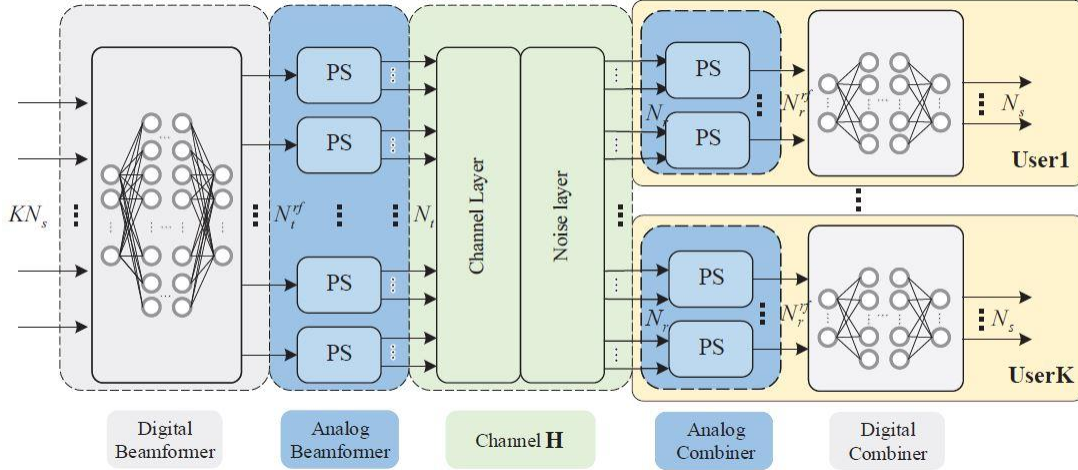


Figure III.9: schéma synoptique matériel simplifié du système MIMO massif multi-utilisateurs de BH à cellule unique de liaison descendante basé sur un codeur automatique.

III.4.3.1.Conception de formateur / combineur numérique :

Pour le formateur / combineur de faisceaux numériques, le signal complexe d'entrée x du réseau neuronal est divisé en deux parties, la partie réelle $\Re(X)$ et la partie imaginaire $\Im(X)$. Par conséquent, le signal d'entrée du réseau neuronal entièrement connecté peut être écrit sous la forme $X = [\Re(X), \Im(X)]$. La fonction d'un réseau neuronal entièrement connecté à une couche est donnée par :

$$Y = [\Re(y), \Im(y)] = [\sigma(W_R \Re(x) - W_I \Im(x) + b_R), \sigma(W_R \Im(x) + W_I \Re(x) + b_I)] \quad (III.15)$$

Où Y est la concaténation de la partie réelle $\Re(y)$, et la partie imaginaire $\Im(y)$ du signal complexe traité y . Les poids du canal réel et imaginaire peuvent être respectivement indiqués par W_R et W_I . Les biais du canal réel et imaginaire peuvent être exprimés par b_R et b_I respectivement. Ici, le symbole $\sigma(\cdot)$ désigne la fonction d'activation.

Le formateur / combineur de faisceaux numérique peut ajuster à la fois la phase et l'amplitude des signaux d'origine sans limitation. De manière concise, le signal traité du formateur de faisceaux numérique est représenté comme:

$$S_D = f_t^n(s; a_t) \quad (III.16)$$

Où $S_D = [\Re(s_D), \Im(s_D)]$ le signal complexe de sortie S_D du réseau neuronal de formateur de faisceau numérique peut être obtenu en combinant le réseau neuronal de formateur de faisceau numérique S_D . De même, le signal du récepteur après la combinaison de bande de base peut être indiqué comme :

$$S = f_r^n(s_A; a_r), \quad (III.17)$$

Où la sortie du réseau neuronal combinateur numérique peut être écrite comme $S = [\Re(S), \Im(S)]$, $S = [S_1, S_2, \dots, S_K]^T$. Ici $S_A = [\Re(s_A), \Im(s_A)]$ représente la sortie du réseau neuronal du combineur analogique. Le signal complexe traité par le combineur analogique s'écrit S_A . En outre, α_r représente l'ensemble de paramètres du canal réel et du canal imaginaire dans le réseau neuronal combinateur numérique à n couches.

III.4.3.2. Conception de formateur / combinateur de faisceaux analogiques :

Les signaux complexes de transmission traités par le formateur de faisceau analogique peuvent être écrits comme :

$$S^t = \rho \left[s_1^t, s_2^t, \dots, s_{N_t}^t \right]^T = \rho \left[\sum_{p=1}^{N_t^{rf}} s_{D,p} 1e^{j\theta_{p,1}^t}, \sum_{p=1}^{N_t^{rf}} s_{D,p} 2e^{j\theta_{p,2}^t}, \dots, \sum_{p=1}^{N_t^{rf}} s_{D,p} N_t^{rf} e^{j\theta_{p,N_t}^t} \right]^T \quad (III.18)$$

Le paramètre de contrôle de puissance ρ est défini comme :

$$\rho = \left(P \sum_{n=1}^{N_t} |s_n^t|^2 \right)^{-1/2}, \quad (III.19)$$

Pour l'utilisateur k, le signal traité par le combineur analogique peut être modélisé comme:

$$S_{A,K} = \left[s_{A,K,1}, s_{A,K,2}, \dots, s_{A,K,N_r^{rf}} \right]^T \\ = \left[\sum_{m=1}^{N_r} s_{K,m}^r 1e^{j\theta_{K,m,1}^r}, \sum_{m=1}^{N_r} s_{K,m}^r 1e^{j\theta_{K,m,2}^r}, \dots, \sum_{m=1}^{N_r} s_{K,m}^r 1e^{j\theta_{K,m,N_r^{rf}}^r} \right]^T \quad (III.20)$$

où $s_{A,K,q}$, $q \in \{1, 2, \dots, N_r^{rf}\}$ désigne le $q^{ème}$ signal de la chaîne RF de l'utilisateur k. Ici, $\theta_{K,mq}^r$, $m \in \{1, 2, \dots, N_r\}$ désigne le paramètre de phase entre la m-ième antenne de réception et la q-ième chaîne RF pour l'utilisateur k. Notez que les formules (II.18) et (III.20) impliquent la multiplication d'un nombre complexe tel que $x e^{j\theta}$, la combinaison avec la formule d'Euler $x e^{j\theta}$ équivaut à :

$$y = x e^{j\theta} = x(\cos \theta + j \sin \theta) \quad (III.21)$$

Dans le réseau neuronal déphaseur, la multiplication dans (III.21) peut être définie comme :

$$Y = [\mathcal{R}(y), \mathcal{I}(y)] = [(\mathcal{R}(x)\cos\theta - \mathcal{I}(x)\sin\theta), (\mathcal{R}(x)\sin\theta + \mathcal{I}(x)\cos\theta)] \quad (\text{III.22})$$

Similaire à l'écriture (III.16) et (III.17) la sortie du formateur / combineur de faisceaux analogique peut être représentée respectivement comme :

$$\begin{aligned} S^t &= g_t(S_D; \theta^t), \\ S_A &= g_r(S^r; \theta^r), \end{aligned} \quad (\text{III.23})$$

Où $g_t(\cdot) / g_r(\cdot)$ désigne le réseau neuronal de formateur / combineur de faisceaux analogique. Les paramètres de phase sont représentés par θ_t / θ_r .

III.4.3.3. Transmission par canal :

La transmission de canal et le processus d'ajout de bruit sont réalisés par un réseau neuronal avec des paramètres fixes, pour tout k-ème utilisateur, qui est indiqué comme :

$$\begin{aligned} S_K^r &= \mathcal{R}(S_K^t), \mathcal{I}(S_K^t) \\ &= [\mathfrak{R}(S^t H_K + n_K), \mathfrak{I}(S^t H_K + n_K)] \end{aligned} \quad (\text{III.24})$$

S^t est le signal transmis à BS, et S_K^r est le signal reçu à l'utilisateur k. La matrice CSI entre l'utilisateur k et la BS est représentée comme H_K . n_K représente le vecteur de bruit correspondant $\text{CN}(0, \rho_K^2)$.

III.4.3.4. Formation des problèmes d'optimisation :

Dans le système multi-utilisateurs, la somme-MSE (III.12) est considérée comme l'erreur de reconstruction. Ainsi, la fonction de perte du DNHB est:

$$\begin{aligned} L = L(S, \hat{S}) &= \sum_{K=1}^K E \left\| S_K - \hat{S}_K \right\|_F^2 \\ &= \sum_{K=1}^K E \left\| \mathcal{R}(S_K) - \mathcal{R}(\hat{S}_K) \right\|_F^2 + \left\| \mathfrak{I}(S_K) - \mathfrak{I}(\hat{S}_K) \right\|_F^2 \end{aligned} \quad (\text{III.25})$$

III.4.4. Résultats de simulation :

Dans les expériences de simulation, la configuration du système MIMO est définie comme suit: $N_t = 64$ à la station de base, $N_r = 16$, $N_r f = 2$ et $N_s = 2$ pour chaque utilisateur. Le nombre de groupes (des clusters) de canaux est 2 et 2 rayons pour chaque cluster.

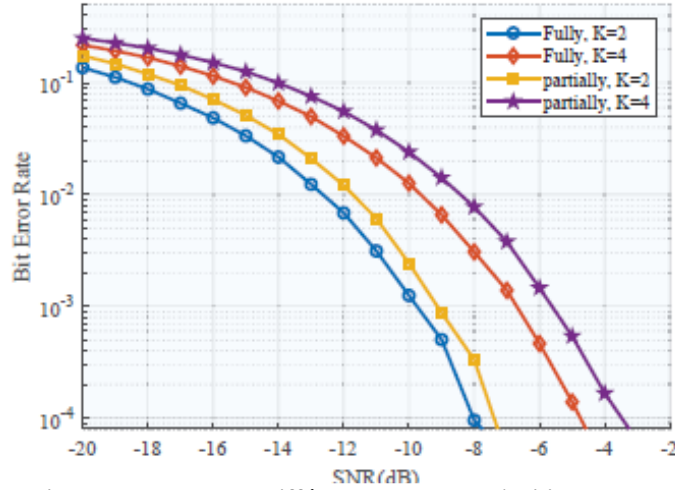


Figure III.10: Comparaison du BER pour différents nombres d'utilisateurs $K = 2, 4$. Les paramètres sont définis comme $N_r^{rf} = 2, N_t^{rf} = KN_r^{rf}$ et le flux de données total est $KN_s = 2 \times K$.

figure III.10 montre la comparaison du BER pour nombre différent d'utilisateurs $K = 2, 4$ en formateur / combineur de faisceaux analogiques entièrement connectés et partiellement connectés. Comme il le montre, le formateur / combineur de faisceau analogique entièrement connecté a des performances supérieures en BER de 3 dB à celles du formateur / combineur de faisceau analogique partiellement connecté. Le formateur / combineur de faisceaux analogiques partiellement connecté a plus de constriction en raison de sa structure. Et 2 utilisateurs ont des performances supérieures que 4 utilisateurs, car les informations entre différents utilisateurs ne peuvent pas être transmises et échangées dans le système multi-utilisateurs. Avec l'augmentation du nombre d'utilisateurs dans le système, ses performances sont suggérées de s'aggraver.

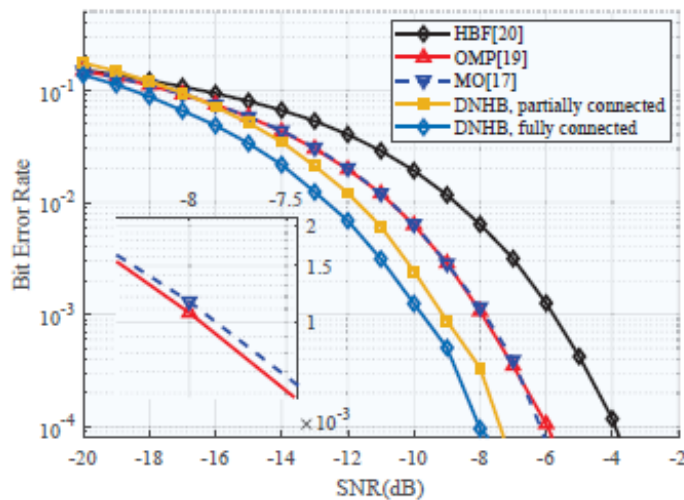


Figure III.11: Comparaison avec certaines méthodes existantes. Les paramètres sont définis comme $K = 2, N_t^{rf} = N_r^{rf} = 2$ et le flux de données total est $KN_s = 4$.

La figure III.11 est la comparaison avec d'autres méthodes de formation de faisceaux existantes dans la littérature de ce domaine de recherche. Ces méthodes sont l'algorithme conventionnel orthogonal matching pursuit (OMP), l'algorithme conventionnel de beamforming hybride (HBF) et l'algorithme HB d'optimisation de manifold (MO). Selon les résultats illustrés par la figure III.11, l'algorithme DNHB proposé dans ce travail présente $2 \square 3$ dB comme avantage de performances.

III.5: Conclusion :

Le MIMO massif est un concept ambitieux qui impose aux chercheurs et concepteurs de systèmes multi-antennaires de résoudre toute une série de problèmes. A travers les exemples donnés dans ce chapitre on a conclu ce qui suit:

- 1- L'emploi de deep-learning améliore considérablement le compromis complexité-performances de l'allocation de puissance, par rapport aux méthodes traditionnelles axées sur l'optimisation.
- 2- Le signal de brouillage est supprimé à l'aide d'une méthode de deep-learning repose sur un modèle basé sur un réseau neuronal à convolution et prend comme entrées le signal reçu et la sortie d'un banc de filtres adaptés.
- 3- Le beamforming hybride employant le deep-learning offre un compromis pour équilibrer les exigences en termes de coûts et de puissance en ayant recours à des composants à la fois analogiques et numériques. Visant des gammes de fréquence plus élevées, ces conceptions combinent des réseaux de beamforming analogiques avec des étapes de prétraitement numériques.

Conclusion générale

La nécessité d'accueillir plus d'utilisateurs avec des débits de données plus élevés avec une meilleure fiabilité et une consommation d'énergie inférieure a conduit à la naissance d'une nouvelle génération de communications mobiles 5G. Dans ce mémoire, nous avons examiné la recherche orientée vers les problèmes fondamentaux de la communication numérique et en nous appuyant sur des techniques avancées de traitement du signal. Dans l'ensemble, le chapitre 1 donne un aperçu de la technologie mobile 5G et de ses projets actuels; et sa position par rapport au réseau 4G dans le monde de la communication sans fil. Les systèmes de communication de nouvelle génération évoluent vers une flexibilité accrue sous différents aspects. La flexibilité de la 5G offre de nombreuses possibilités de recherche ouvertes par rapport aux générations précédentes de connexions cellulaires. L'accent a également été mis sur les systèmes MIMO massifs. Les systèmes d'antennes à entrées multiples (MIMO) deviennent rapidement une technologie sans fil inévitable car la technologie MIMO permet la transmission parallèle et simultanée de données sur la même fréquence avec plusieurs antennes au même niveau. Pour l'émetteur et le récepteur, cela peut être utilisé pour augmenter le débit et réduire le taux d'erreur sur les bits (BER). Bien que la technologie massive MIMO supprime bon nombre des problèmes de recherche traditionnels, il reste des défis à réaliser pour réaliser le plein potentiel de la technologie, en notant la complexité du calcul, en réalisant des algorithmes de traitement distribués, le problème du chevauchement de la contamination intra et intracellulaire et de la contamination expérimentale.

C'est pourquoi nous avons abordé dans le deuxième chapitre le deep learning, qui joue un rôle de plus en plus important dans le domaine des réseaux mobiles et sans fil. Nous avons résumé les concepts de base et les principes avancés des différents modèles de deep learning.

Et sa relation avec l'intelligence artificielle, l'apprentissage automatique et les réseaux de neurones, nous avons donc noté que l'utilisation de techniques avancées d'apprentissage automatique (intelligence artificielle) dans les futurs réseaux mobiles est la meilleure solution pour aider à gérer le volume croissant de données et d'applications reposant sur des algorithmes grâce au développement de systèmes de réseau prenant en charge l'apprentissage automatique.

Conclusion Générale

Enfin, dans le dernier chapitre, nous avons discuté de trois applications importantes de l'apprentissage profond, nous avons donc essayé d'expliquer le travail de chaque exemple et de discuter des résultats obtenus, l'application de l'apprentissage profond connu sous le nom deep learning représente un grand défi pour les systèmes 5G multi-antennes, car il garantit une solution à de nombreux problèmes avec une très grande efficacité comme l'estimation de canal, atténuation expérimentale de la pollution, codage de source et de canal, formation de faisceaux ... etc.

Références bibliographiques

- [1]: Khawla. Daci, Warda. Dou, “Etude de massive MIMO pour 5G,”Mémoire de MASTER.Université Echahid Hamma Lakhdar El-Oued,2019.
- [2]:C. Zhang, P. Patras, and H. Haddadi,“Deep Learning in Mobile and Wireless Networking:A Survey,” article IEEE IEEE Communications surveys & tutorials,2019.
- [3]: Heba Soffar, “5G network features, uses, importance, dangers, What is 5g technology & How it works?,”page de web, 9 Mars 2019.
- [4]: Menal Dahiya, “Need and Advantages of 5G wireless Communication Systems,” article Dept. of Computer Science Maharaja Surajmal Institute C-4, Janakpuri, Delhi – India, June 2017.
- [5]: Samir Ahmed, “Beamforming management and beam training in 5G system,” Master of Science Thesis, Master of Science in Electrical Engineering,Tampere University,November 2019.
- [6]: Rajiv, “What is 5G NR (new radio) and how it works,” page de web, 16 October 2017.
- [7]: Hossein Shokri-Ghadikolei, “Millimeter-wave Networking : Fundamental Limits, Scalable Algorithms, and Design Insights,” Doctoral Thesis in Telecommunications,Stockholm, Sweden, 2017.
- [8]: Raed Shubair, Fatima Al-Ogaili, “Millimeter-Wave Mobile Communications for 5G: Challenges and Opportunities,”Electrical and Computer Engineering Department, Khalifa University, UAE, June 2016.
- [9]: [Http://www. the-emergence-of-5g-mmwave/accton.com](http://www.the-emergence-of-5g-mmwave/accton.com)
- [10]: Mustafa Khaleel, “Millimeter wave mobile communication, ” site de web,11 janvier 2016.
- [11]: Ayman Hallal, “Génération d’ondes millimétriques et submillimétriques sur des systèmes fibrés à porteuses optiques stabilisées, ” Optique / photonique.Thèse Doctorat, Université Rennes, France, 2017.
- [12]: Rajiv, What are small cells in 5G technology,page de web,5 September 2018
- [13]: Ade Syaheda, Wani Marzuki,“Mobile small cell networks for next generation wireless communication systems, ” Thèse Doctorat , Edith Cowan University,2018
- [14]: EMIL BJÖRNSSON, “MASSIVE MIMO : NEWS-COMMENTARY-MYTHBUSTING, ”page de web, JUNE 22, 2018.

Références bibliographiques

- [15]: Hien Quoc Ngo, “Massive MIMO: Fundamentals and System Designs, ” Linköping Studies in Science and Technology, Sweden,2015.
- [16]: E. Björnson, J. Hoydis, and L. Sanguinetti, “Massive MIMO Networks: Spectral, Energy, and Hardware Efficiency, ”Liver, Foundations and Trends in Signal Processing,2017.
- [17]: X. Gao, O. Edfors, F. Rusek, and F. Tufvesson, “Linear pre-coding performance in measured very-large MIMO channels,” in Proc. IEEE Vehicular Technology Conf. (VTC), San Francisco, CA, US, Sept. 2011.
- [18]: Salah Eddine Hajri, “L’amélioration des performances des systèmes sans fil 5G par groupements adaptatifs des utilisateurs,” Thèse Doctorat, Sciences de l’information et de la communication. Université Paris-Saclay, 2018.
- [19] : Rozé, Antoine, “Massive MIMO, une approche angulaire pour les futurs systèmes multi-utilisateurs aux longueurs d’onde millimétriques,” thèse, Diss. INSA de Rennes, 2016.
- [20] : Amy Nordrum, Kristen Clark, “Full duplex could double the capacity of wireless networks, making it a key technology for 5G,” IEEE Spectrum Staff, 01 Apr 2017.
- [21] : “5G, the Internet of Things (IoT) and Wearable Devices: What do the new uses of wireless technologies mean for radio frequency exposure?,” GSMA Head office,The Walbrook Building ,London United Kingdom, October 2019.
- [22]: Afif osseiran, Jose F. Monserra, Patrick Marsch “5G Mobile and Wireless Communications Technology, ”Livre, New York : Cambridge University Press, 2016.
- [23]: P.Wallström, “Device-To-Device Communications For 5G Radio Access Networks , ” Mémoire de Master, Université de Aalto 9 Avril 2015.
- [24] : W. Xiang, K. Zheng, X. Sherman , “5g Mobile Communications , ” Livre, 14 octobre 2016.
- [25] : W. Robert, Heath Jr, Angel Lozano, “Five Disruptive Technology Directions For 5g, ” article IEEE Communications, Février 2014.
- [26] : M. Roche, Edward, H. Dickens-Jr Benjamin, et Walker Townes, “La prochaine génération de téléphonie mobile (5G) et ses implications (Infrastructure, Réglementation) , ”journal openedition, *Netcom*, 32-1/2 | 139-162,2018.
- [27] : <http://www.5GEXPLAINED-HOW5GWORKS.COM>
- [28] : E.Hossain, M. Rasti, H. Tabassum, A. Abdel Nasser “Evolution towards 5g Multi-Tier Cellular Wireless Networks: An Interference Management Perspective,” IEEE Wireless Communications Conférence, 17 Feb 2014.

Références bibliographiques

- [29]: Temmar Louiza et Bouaka Asma ,“Simulation d’un réseau d’antennes pour les mobiles 5G avec CST Microwave Studio,” Mémoire de Master , Université Kasdi Merbah Ouargla ,25juin2018 .
- [30] : Mariam Khaled Alsedrah, “Artificial Intelligence,”Article, The American University of the Middle East,December 2017.
- [31] : <https://www.utc.edu/registrar/pdfs/2015undergradcurr/15-179/cpsc4430-syllabus-dec2014.pdf> “Introduction to Machine Learning CPSC 4430,”Course Description
- [32]: Hans-Dieter Wehle, “Machine Learning, Deep Learning, and AI: What’s the Difference? ,” Conference: Data Scientist Innovation Day, July 2017.
- [33]: Claude Touzet, “Réseaux de neurones artificiels, une introduction à la communication: Cours, exercices et travaux pratiques. EC2, ”archive, Collection de l’EERIE,1992.
- [34]: David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *Nature*, 323(6088):533,1986.
- [35]: Luis Perez and Jason Wang. The effectiveness of data augmentation in image classification using deep learning. *arXiv preprint arXiv:1712.04621*, 2017.
- [36] L. Sanguinetti, A. Zappone, and M. Debbah, “Deep learning power allocation in Massive MIMO,” in *Proc. ASILOMAR*, 2018.
- [37] M. Pajovic, T. Koike-Akino, and P. V. Orlik, “Model-driven deep learning method for jammer suppression in massive connectivity systems,” *arXiv preprint arXiv:1903.06266*, 2019.
- [38] Jiyun Tao, Jing Xing, and Jienan Chen, ‘Hybrid Beamforming/Combining for Millimeter Wave MIMO: A Machine Learning Approach’, Published in 2020, *Electrical Engineering and Systems Science*, *arXiv: Signal Processing*.
- [39] T. Lin, J. Cong, Y. Zhu, J. Zhang, and K. Ben Letaief. Hybrid beamforming for millimeter wave systems using the mmse criterion. *IEEE Transactions on Communications*, 67(5):3693–3708, May 2019.
- [40] M. Joham, W. Utschick, and J. A. Nossek. Linear transmit processing in mimo communications systems. *IEEE Transactions on Signal Processing*, 53(8):2700–2712, Aug 2005.