



Centre de Développement des Technologies Avancées



RAPPORT DE STAGE PFE- MASTER

Optimisation Des Performances D'un Système MIMO Massif Par
Les Méthodes D'apprentissage Profond.

Stagiaire :

Aya KHODJA

Etudiante En Master 2 Informatique, parcours
Informatique Embarquée, ISAE-ENSMA.

Maitre de stage :

Fatma Zohra BOUCHIBANE

Maitre de recherche B, CDTA.

Enseignant référant :

Allel HADJALI

Professeur en
Informatique, ENSMA.

Début : 10/05/2022

Fin : 01/11/2022

Remerciements

Ce travail devient une réalité avec le soutien de nombreuses personnes.

Ces lignes me donnent l'occasion de les remercier,

Tous d'abord, je tiens à remercier vivement mon maitre de stage, Madame BOUCHIBANE Fatma Zohra, Maitre de recherche au Centre de Développement des Technologies Avancées, pour sa gentillesse, son accueil chaleureux. Elle a su prendre le temps pour que je cerne la problématique rapidement et que je sois autonome dans mes actions, elle m'avait soutenu toute au long de ce stage et m'a fait confiance pour que je les remplisse.

J'adresse également ma gratitude mon à prof de référence Monsieur Allel HADJALI, professeur en informatique à L'ENSMA, pour sa disponibilité et ses conseils précieux.

Je tiens également à remercier le Pr Brice Chardin pour avoir fait partie du jury et accepter d'examiner ce modeste travail.

Ainsi mes chaleureux remerciements s'adressent à mes parents et ma famille qui m'ont encouragé à accomplir ce mémoire.

J'adresse mes remerciements à Madame la directrice BENKHEDA Amina et le Professeur Mohamed LAGHA, de l'institut d'aéronautique de Blida, pour tous les services qu'ils m'ont fournis et continuent de fournir jusqu'à présent.

Enfin, j'adresse mes remerciements à l'agence d'ERASMUS+, à qui l'on attribue le mérite de m'avoir rejoint dans cette famille universitaire.

Résumé :

Les systèmes Massive Multiple Input Multiple Output (MIMO) représentent une technologie très récente et prometteuse pour les réseaux mobiles 5G qui garantit une amélioration significative en termes d'efficacité spectrale (SE) et d'efficacité énergétique (EE). Le principe est d'installer un grand nombre (voir centaines) d'antennes au niveau de la station de base (BS) pour servir d'utilisateurs. En effet, grâce à la technique de Beamforming, des débits importants peuvent être atteints sans avoir à élargir le spectre de fréquence utilisé. Ainsi, les systèmes Massive MIMO peuvent répondre aux exigences du nombre explosif d'appareils connectés dans l'avenir. Cependant, le nombre accru d'antennes augmente la consommation de l'énergie à cause des chaînes radio fréquence (RF) associées à chaque antenne. D'où la technique de sélection d'antenne (SA) est nécessaire pour réduire cette consommation. Dans notre travail, nous proposons un algorithme de SA à complexité réduite basé sur le réseau de Neurone Convolutif (CNN). Cet algorithme est évalué sur plusieurs configurations et dans des scénarios différents en exploitant des données de mesure réelles dans un environnement Indoor. Les résultats obtenus sont comparés par celles obtenus par la méthode de sélection d'antenne optimale proposée dans la littérature. Des performances comparables sont obtenues avec un temps de calcul considérablement réduit.

Abstract

Massive Multiple Input Multiple Output (MIMO) systems represent a very recent and promising technology for 5G mobile networks that guarantees a significant improvement in terms of spectral efficiency (SE) and energy efficiency (EE). The principle is to install a large number (even hundreds) of antennas at the base station (BS) to serve as users. Through the beamforming technique, high throughputs can be achieved without having to widen the frequency spectrum used. Thus, Massive MIMO systems can meet the demands of the explosive number of connected devices in the future. However, the increased number of antennas increases power consumption due to the radio frequency (RF) channels associated with each antenna. Hence the technique of antenna selection (SA) is necessary to reduce this consumption. In our work, we propose a reduced complexity SA algorithm based on the Convolutional Neural Network (CNN). This algorithm is evaluated on several configurations and in different scenarios by exploiting real measurement data in an indoor environment. The results obtained are compared with those obtained by the optimal antenna selection method proposed in the literature. Comparable performances are obtained with a considerably reduced calculation time.

Acronymes

AS	Antenna selection
BS	Base Station
CSI	Channel State Information
CNN	Réseau de neurones convolutif ou Convolutionnal Neural Network
DL	Downlink
EE	Energy Efficiency
FDD	Frequency -Division Duplex
GD	Descente de Gradient ou Gradient Descent.
MIMO	Multi Input Multi Output
MISO	Multi Input Single Output
MU-MIMO	Multi-User MIMO
NR	New Radio
ReLU	Rectified Linear Unit
RF	Radio Frequency
SE	Spectral Efficiency
SIMO	Single Input Multi Output
SISO	Single Input Single Output
SNR	Signal-to-Noise Ratio
SVM	Support Vector Machines
TDD	Time-Division Duplex
UL	Up Link
UT	User Terminal
ZF	Zero Forcing

Liste des tableaux

Table 1 : le temps du calcule pour $N_t=32$, $N_s=16$.

Table 2 : le temps du calcule pour $N_t=32$, $N_s=20$.

Table 3 : le temps du calcule pour $N_t=32$, $N_s=24$.

Table 4 : le temps du calcule pour $N_t=32$, $N_s=28$.

Table 5 : le temps du calcule pour $N_t=32$, $N_s=30$.

Table 6 : le temps du calcule pour $N_t=64$, $N_s=16$.

Table 7 : le temps du calcule pour $N_t=64$, $N_s=24$.

Table 8 : le temps du calcule pour $N_t=64$, $N_s=32$.

Table 9 : le temps du calcule pour $N_t=64$, $N_s=56$.

Table 10 : le temps du calcule pour $N_t=128$, $N_s=16$.

Table 11 : le temps du calcule pour $N_t=128$, $N_s=32$.

Table 12 : le temps du calcule pour $N_t=128$, $N_s=48$.

Table 13 : le temps du calcule pour $N_t=128$, $N_s=96$.

Table 14 : le temps du calcule pour $N_t=64$, $N_s=16$, ULA.

Table 15 : le temps du calcule pour $N_t=64$, $N_s=24$, ULA.

Table 16 : le temps du calcule pour $N_t=64$, $N_s=32$, ULA.

Table 17 : le temps du calcule pour $N_t=64$, $N_s=56$, ULA.

Table 18 : le temps du calcule pour $N_t=64$, $N_s=16$, URA.

Table 19 : le temps du calcule pour $N_t=64$, $N_s=24$, URA.

Table 20 : le temps du calcule pour $N_t=64$, $N_s=32$, URA.

Table 21 : le temps du calcule pour $N_t=64$, $N_s=56$, URA.

Table 22 : le temps du calcule pour $N_t=64$, $N_s=16$, D.

Table 23 : le temps du calcule pour $N_t=64$, $N_s=24$, D.

Table 24 : le temps du calcule pour $N_t=64$, $N_s=32$, D.

Table 25 : le temps du calcule pour $N_t=64$, $N_s=56$, D.

Liste des figures

Figure 2.1 : chronologie de l'évolution du réseau cellulaire mobile [1].

Figure 2.2 : Réseau cellulaire.

Figure 3.1 : Schéma Système MIMO.

Figure 3.2 : Schéma Système SISO.

Figure 3.3 : Schéma Système MISO.

Figure 3.4 : Schéma Système SIMO.

Figure 3.5 : Schéma Système MIMO.

Figure 3.6 : Une illustration de MIMO massive.

Figure 3.7 : Modèle de base de MASSIVE MIMO.

Figure 4.1 : schéma présentatif de la méthode de selection d'antenne.

Figure 5.1 : Le perceptron.

Figure 5.2 : Le perceptron multi-couches.

Figure 5.3 : le principe de la rétro propagation pour l'entraînement des réseaux de neurones.

Figure 5.4 : Architecteur d'un CNN.

Figure 5.5 : principe de convolution.

Figure 5.6 : principe de Pooling.

Figure 6.1 : modèle de sélection d'antenne par CVX Figure 6.2 modèle sélection d'antenne par la méthode ML-CNN.

Figure 6.3 : la variation de F-score et Loss dans la partie d'entraînement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=10$.

Figure 6.4 : la variation de la capacité maximale en fonction de N_s pour $N_t=32$, $SNR= 10$.

Figure 6.5 : la variation de la capacité maximale en fonction de N_s pour $N_t=64$, $SNR= 10$.

Figure 6.6 : la variation de la capacité maximale en fonction de N_s pour $N_t=128$, $SNR= 10$.

Figure 6.7 : la variation de la capacité maximale en fonction de SNR pour $N_t=64$, $N_s= 52$.

Figure 6.8 : la variation de F-score et Loss dans la partie d'entraînement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=15$.

Figure 6.9 : la variation de la capacité maximale en fonction de N_s , $SNR= 10$.

Figure 6.10 : la variation de la capacité maximale en fonction de SNR , $N_s= 24$.

Figure 6.11 : la variation de F-score et Loss dans la partie d'entraînement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=10$.

Figure 6.12 : la variation de la capacité maximale en fonction de N_s , $SNR= 15$.

Figure 6.13 : la variation de la capacité maximale en fonction de SNR , $N_s= 16$.

Figure 6.14 : la variation de F-score et Loss dans la partie d'entraînement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=10$.

Figure 6.15 : la variation de la capacité maximale en fonction de N_s , $SNR= 10$.

Figure 6.16 : la variation de la capacité maximale en fonction de SNR , $N_s= 56$.

Table des matières

Chapitre 01 Introduction et objectif	1
1.1 Introduction.....	1
1.2 Présentation de l'entreprise CDTA.....	2
1.3 Organisation du rapport de stage	3
1.4 La problématique	4
1.5 Etude bibliographique.....	4
Chapitre 02 5 ^{ème} GENERATION	6
2.1 Introduction.....	6
2.2 Evolution de la communication mobile.....	6
2.3 Réseau mobile 5G.....	7
2.4 Les points importantes de la 5G	7
2.5 Les technologies de la 5G.....	7
2.5.1 Communications dans la plage des ondes millimétriques	7
2.5.2 Entrée multiple sortie multiple massif (mMIMO)	8
2.6 Objectifs de la 5G	8
2.7 Réseau cellulaire	8
2.8 NEW RADIO (NR)	10
2.9 Bande Passante du Canal NR	10
2.10 Conclusion	11
Chapitre 03 MASSIVE MIMO	12
3.1 Introduction.....	12
3.2 SYSTEME MIMO.....	12
3.3 Principe de MIMO	13
3.4 Type MIMO.....	13
3.5 Evolution de MIMO vers le MASSIVE MIMO.....	16
3.6 MASSIVE MIMO	17
3.7 La Diversité Spatiale.....	18
3.8 Multiplexage spatial.....	18

3.9	Beamforming	19
3.10	Le canal de transmission :	19
3.11	Estimation du canal :	19
3.11.1	Estimation du canal dans le TDD système :.....	19
3.11.2	Estimation du canal dans le FDD système	20
3.12	Massive MIMO préfère TDD Schéma	21
3.13	Calcul de capacité	21
3.14	Avantage de la technologie MASSIVE MIMO.....	21
3.15	Efficacité Energétique EE.....	23
3.16	Efficacité Spectrale.....	25
3.17	Utilité de MASSIVE MIMO pour la 5G	26
3.18	Conclusion	26
Chapitre 04 La selection d'antenne.....		27
4.1	Introduction.....	27
4.2	La Méthode de Sélection d'Antenne AS	27
4.3	Les méthodes approuvées par La Sélection d'Antenne.....	28
4.3.1	optimization-driven méthodes.....	28
4.3.2	data-driven méthodes	28
4.4	La méthode d'optimisation convexe.....	29
4.5	Optimisation de l'efficacité énergétique par la AS	31
4.6	Conclusion	31
Chapitre 05 Deep Learning		32
5.1	Introduction.....	32
5.2	Définition de l'apprentissage profond (Deep Learning)	32
5.3	Principe	33
5.3.1	Le perceptron.....	33
5.3.2	Perceptron multi-couches MLP.....	34
5.3.3	L'entraînement	35
5.3.4	Validation	37
5.3.5	Evaluation la qualité de l'entraînement.....	37
5.4	Réseaux de neurones convolutifs CNN.....	37

5.5	Structure des CNN	38
5.6	Les problèmes de classification.....	41
5.5.1	Les différents types de classifications.....	41
5.5.2	Limite de classification multi-classe	42
5.7	Conclusion	42
6.1	Introduction.....	44
6.2	Modèle du système	44
6.3	Sélection d'antenne.....	45
6.3.1	CVX Méthode d'optimisation convexe.....	46
6.3.2	ML-CNN	47
6.4	Simulation et Interprétation des Résultats	48
6.5	Conclusion	69
	Conclusion générale	68
	Référence.....	69

Partie
Théorique Et
Etat de l'Art

1.1 Introduction

Le monde a constaté une augmentation considérable du pourcentage d'utilisateurs d'appareils de communication sans fil, comme les téléphones intelligents, les tablettes, les ordinateurs portatifs et divers autres appareils sans fil. En parallèle une augmentation massive sur la demande de trafic de données pour le réseau sans fil. Alors Le besoin d'accueillir plus d'utilisateurs simultanément en temps réduit 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 qu'est la 5G basant, parmi autre, sur la technique MIMO (multi-input, multi-output) massive. Cette technique est basée sur le bénéfice de trajet multiple pour améliorer la capacité de système. Elle convient notamment à la technologie des ondes millimétriques.

Dans cette étude, nous nous intéressons à l'optimisation d'énergie dans l'une des technologies clés de la cinquième génération de la téléphonie mobile, Massive multiple entrée multiple-sortie MIMO. L'utilisation des antennes à grande échelle signifie des grands nombres des canaux radiofréquence (RF). En considérant la consommation énergétique et le coût élevé des chaînes RF, une sélection d'antenne sera nécessaire pour les systèmes de communication sans fil Massive MIMO dans l'un des extrémités de transmission et de réception finale.

Dans ce travail, on va proposer un réseau de neurone convolutif (CNN) pour la sélection d'antenne dans un système MIMO Massif. Nous considérons des données de simulations ainsi que des données de mesures pour l'apprentissage et la validation du réseau.

Différents scénarios sont simulés et les résultats sont comparés avec les résultats obtenus en exploitant l'algorithme de sélection d'antenne optimal.



1.2 Présentation de l'entreprise CDTA

Le Centre de Développement des Technologies Avancées (CDTA) est un établissement public créé en 1988 à Alger-Algérie de secteur scientifique et technologique, Il a pour mission d'effectuer les travaux de recherche scientifique, d'innovation technologique, de valorisation et de formation dans les domaines des sciences et des technologies de l'information, des technologies industrielles et de la robotique, des dépôts et des traitements des matériaux, des applications et des technologies des lasers.

Les divisions du CDTA :

- Architecture des Systèmes et Multimédias.
- Milieux Ionisés et Lasers.
- Microélectronique et Nanotechnologie.
- Productique, Robotique.
- Telecom (c'est le domaine de mon stage).

1.3 Organisation du rapport de stage

Ce rapport est structuré en deux parties, la partie théorique et état d'art et la partie pratique et simulation.

La première partie est composée de Cinq chapitres, introduction et objectif la 5G, MASSIVE MIMO, la sélection d'antenne et Deep Learning, c'est la partie où nous allons aborder les différents concepts de base, utilisés dans la deuxième partie, qui sont l'application et la simulation de notre méthode proposée.

1.4 La problématique

« La mise en œuvre d'un réseau neuronal convolutif fait de la sélection d'antenne un moyen optimal afin d'améliorer les performances d'un système MASSIVE MIMO que les méthodes d'optimisation traditionnelle »

1.5 Etude bibliographique

MASSIVE MIMO

En 2010, FOSCHINI GERARD, le scientifique du laboratoire Bell Marzetta, a proposé pour la première fois le concept de MASSIVE MIMO dans les scénarios multi-cellules et Time Division Duplexing (TDD) [8].

La sélection d'antenne

En [20], l'auteur a traité l'application de la méthode de sélection d'antenne par le Deep Learning sur un système MIMO, alors que ce travail consiste à appliquer la méthode de sélection d'antenne par le Deep Learning sur un système MASSIVE MIMO, et puisque ces deux derniers ont le même principe ce qui rend cet article très utile pour notre travail. Tel que il a comparé les méthodes de sélection d'antenne basé sur différents architecteur de CNN, la méthode ResNet, la méthode AlexNet, la méthode LetNet, la méthode VGG-16, la méthode RNN et TSTVM, il a prouvé par son travail que la méthode basé sur l'architecteur LetNet est la meilleure pour la sélection d'antenne d'un système MIMO en terme de performance pour trouver l'étiquette optimale.

En,[21] l'auteur a utilisé la Méthode AS basé sur le Data , par SVM et KNN, grâce à ces études, il a pu prouver que la méthode de sélection d'antenne basé sur le Data est meilleure que celle basé sur l'optimisation en terme de performances et complexité du calcul , tel qu'il a fait une comparaison entre le SVM et KNN (Data) et deux autre modèle valeur propre et valeur canal Max-Min (optimisation).

En ,[26] l'auteur a considéré que la sélection d'antenne est un problème de minimisation de taux d'erreur moyen, et convertie en un cadre de processus décisionnel de Markov qui a été résolu par des schémas de recherches heuristique .

En, [27] l'auteur a utilisé le critère Min-Max simple quasi-optimal et les combinaisons d'AS basé sur les critères de débit de somme maximal (Max-SR) et taux d'erreur de symbole minimal (Min-SER).

La méthode d'optimisation convexe

Nous avons décidé d'utiliser la méthode CVX dans notre travail afin de trouver l'étiquette optimale, sur la base de l'article [23], tel que une grande partie des informations que nous avons mentionnées dans cette section proviennent de l'article de ce dernier, qui a affirmé que les méthodes d'optimisation basé sur les algorithmes CVX sont meilleures que celles basées sur les algorithmes traditionnels en termes de facilité et de flexibilité où :

Il discute les méthodes de points intérieurs dans un problème de minimisation avec deux contraintes d'inégalité. Il a proposé un algorithme pour construire des conceptions optimales via CVX, basé sur quatre étapes principales : la première étape consiste à entrer la valeur du paramètre pour θ et les points de conception x_1, \dots, x_N . Ensuite la deuxième étape, il calcule les matrices d'information $q \times q I_{x_j}(\theta)$ à chaque x_i pour $i = 1, \dots, N$. Dans la troisième étape il Utilise CVX pour résoudre l'équation objectif pour w et dénotez la solution par \hat{w} . Finalement dans la quatrième étape il fait la vérification de l'optimalité de \hat{w} .

2.1 Introduction

L'évolution du réseau sans fil est dans la continuité depuis sa première découverte, où elle représente un changement dans la nature du système, fréquence, vitesse, capacité des données. De la première génération à la cinquième génération, chaque génération diffère de celle qu'elle précède par ses caractéristiques et ces fonctionnalités. Chaque génération est considérée comme une évolution de la génération précédente en termes de capacité, techniques, etc. Le réseau de Communication sans fil mobile de première génération (1G) était analogique utilisé seulement pour les appels vocaux. Ensuite, le service de messagerie s'est ajouté à ce dernier pour devenir la deuxième génération (2G), La troisième génération (3G) a fourni un taux de transmission de données plus élevé. La quatrième génération (4G) intègre la 3G à internet fixe pour prendre en charge internet mobile sans fil, qui est une évolution de la technologie mobile et qui surmonte les limites de la 3G. Elle augmente également la bande passante et réduit le coût de ressources. La 5ème génération de technologie Mobile est considérée comme une véritable richesse dans le domaine des télécommunications sans fil, par les avantages et les services qu'elle apporte, notamment la rapidité des données, ce qui en fait de plus en plus la demande.

2.2 Evolution de la communication mobile

Les réseaux mobiles ont connu une évolution très importante depuis le lancement du premier réseau mobile aux Etats Unis, est suivant :

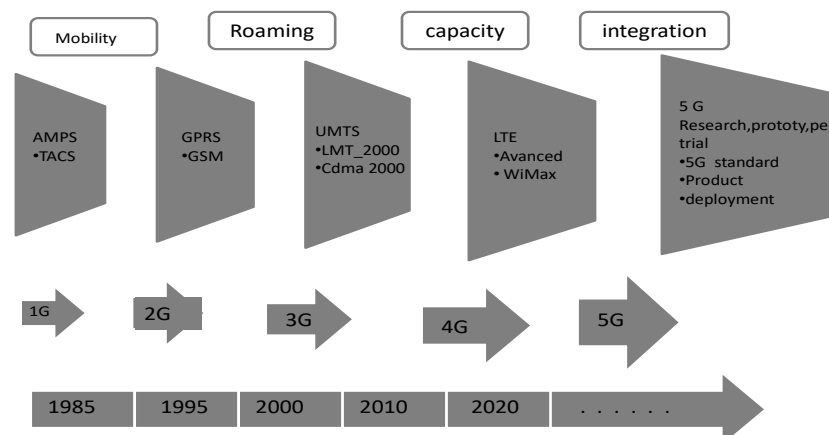


Figure 2.1 : chronologie de l'évolution du réseau cellulaire mobile [1].

2.3 Réseau mobile 5G

La 5G nécessite de prendre en parallèle l'augmentation du volume de trafic, et le défi de connecter des milliards d'appareils avec les besoins de service Hétérogènes. Les réseaux de 5G fournir beaucoup d'améliorations [2].

2.4 Les points importantes de la 5G

La latence

Le temps de latence, représente le temps entre la transmission et la réception d'une donnée. Avec la 5G ce temps est minimisé 10 fois par rapport à la 4G, ainsi un temps de réponse d'à peine une milliseconde.

Cette réactivité est cruciale pour l'industrie, car des échanges constants et quasi-immédiats sont requis pour faire émerger des usages comme le transport autonome [2].

La capacité de téléchargement

Les débits avec la 5G sont 10 fois plus élevé qu'en que 4G certainn station fournit jusqu'au 20Gbits/s

Densité :

La 5G intègre l'Internet des objets, ce qui lui permet de gérer des millions de connexions.

2.5 Les technologies de la 5G

Aujourd'hui le répondre aux besoins de la communication sans fil nécessite un changement radical et des innovations perturbatrices dans le système réseau. Parmi les innovations dans la couche physique 5G, on peut citer :

2.5.1 Communications dans la plage des ondes millimétriques

Parmi les caractéristique de La 5G est qu'elle utilise de très hautes fréquences (extremely high frequencies ; "mmWaves").le monde a besoin d'un spectre supplémentaires de 1000 à 2000 MHz, tandis que la ressource de basse fréquence aura été largement épuisée. Comparées à la bande de basse fréquence utilisée, les ressources de fréquence disponibles dans

la bande d'ondes millimétriques (30–300 GHz) associées à une longueur d'onde de 10 mm à 1 cm, ce qui correspond à environ 200 fois la bande de basse fréquence.

Cependant, ces fréquences plus élevées ont des problèmes de propagation du signal sur une grande distance [3].

2.5.2 Entrée multiple sortie multiple massif (mMIMO)

Massive MIMO est une technologie du moderne qui fournira des réseaux large bande utilisant un très grand nombre d'antennes de service (par exemple, des centaines ou des milliers) qui fonctionnent de manière totalement cohérente et adaptative. Des antennes supplémentaires aident en concentrant la transmission et la réception de l'énergie du signal dans des régions de plus en plus petites de l'espace. MIMO Massif est une forme particulière du système MIMO multi utilisateurs où les stations de bases et le nombre d'utilisateurs sont très nombreux [4].

2.6 Objectifs de la 5G

La 5G IOT vise à : faciliter l'émergence d'un immense écosystème IOT (l'internet des objectifs Est une technologie qui promet de fournir des connexions et des téléchargements plus rapides que les autre générations

- Un temps de latence plus court donc le réseau est très réactif
- la vitesse de transmission des données plus élevée.
- (1 milliseconde de latence). 100% de couverture. 90% de réduction en utilisation énergie du réseau.
- Jusqu'à 10 ans de durée de vie de la batterie.
- 1000 fois plus de bande passante par unité de la surface.
- Jusqu'à 100 fois plus d'appareils connectés par unité de surface.
- 99,999% de disponibilité.
- La vitesse de transmission des données est double par rapport à 4G. [5]

2.7 Réseau cellulaire

On appelle un réseau cellulaire ensemble de stations de base (BS) et un ensemble d'équipements utilisateurs (UE). Chaque équipement est connecté à l'un des BS, qui lui fournit des services, comme illustré à la Figure 2.



Figure 2.2 Réseau cellulaire

Un réseau cellulaire est caractérisé par son débit surfacique qui peut être mesurer par cette équation :

$$\text{Débit de surface [bit/s/km}^2 \text{]} = B \text{ [Hz]} \cdot D \text{ [cells/km}^2 \text{]} \cdot SE \text{ [bit/s/Hz/cell]} \quad (1.1)$$

Avec : B la largeur de bande de communication.

 D la densité de cellules moyenne.

 SE l'efficacité spectral par cellule.

On peut améliorer le débit de couverture des réseaux cellulaires par une des manières suivantes :

Allouer plus de bande passante :

Allouer plus de bande passante signifie augmentation dans le spectre de fréquences, qui considéré comme une ressource naturelle très cher et éteint. Ainsi cette dernière limite la portée de la communication. Malgré cela, des bandes de longueurs d'onde millimétriques peuvent être utilisées pour les applications à courte portée.

Ajouter plus de BS.

Installer plus de BS, l'installation des BS est fait loin aux terminaux, ce qui impose les risques d'être dans l'ouverture, réduisant ainsi la couverture. Ce sont les principales [6].

Améliorer la SE

Consiste à installer plus des antennes à la station de base qui collectent plus d'énergie à partir des ondes électromagnétiques

2.8 NEW RADIO (NR)

Le 5G NR est une nouvelle technique d'accès radio développée, consiste à une norme mondiale pour l'interface air des réseaux par le 3GPP pour les réseaux mobiles 5G, qui se base sur les normes suivantes [7] :

- **Formes d'onde basées sur OFDM**

Consiste a utiliser une forme d'onde optimisée basée sur OFDM, utilisé pour la 5G par le réseau LTE et WIFI, ce qui rend la 5G utilise une conception à accès multiple et assure un multiplexage efficace pour tous les différents cas d'utilisation, des capacités plus élevé.

- **Des technologies sans fil avancées**

Qui permettant d'augmenter la gamme de services 5G.

- **Cadre flexible commun**

Qui permettre un multiplexage efficace, afin d'élever les performances du service.

2.9 Bande Passante du Canal NR

Le NR fonctionne avec une largeur de canal de 100 MHz avec des bandes inférieures.

$$CBW = (N_{RB} \times N_{SP} \times \Delta f + 2 \times BG)$$

CBW : la bande passante de canal.

N_{RB} : Nombre de ressource block.

N_{SP} : Nombre de sous porteuse = 12.

BG : la bande de garde.

2.10 Conclusion

L'augmentation de nombre d'utilisateur de la quatrième génération nécessite un réseau plus fort en terme de performance pour répondre aux besoins d'utilisateurs, ce qui impose le développement d'une nouvelle technologie plus performante, assurer un débit plus élevé, moins de latence, c'est la 5G qui se base à un nouvelle radio NR et l'utilisation des nouvelles technologies comme le MASSIVE MIMO.

3.1 Introduction

La cinquième génération exigeait l'utilisation des systèmes de communication plus puissants et fiables, afin d'améliorer le plus possible les performances de communication pour répondre aux besoins des utilisateurs de communication sans fil. Dans ce cadre les opérateurs ont préféré la technologie de Massive mimo, qui assure notamment une meilleure amélioration en plusieurs termes, pour cela ce chapitre vise à présenter le système Massive mimo, ces caractéristiques qui en ont fait une technologie privilégiée, leur utilité pour la 5G, on passe d'abord par les systèmes MIMO traditionnelle [8].

3.2 SYSTEME MIMO

Le système MIMO consiste à installer plusieurs antennes à l'émission et à la réception (d'une antenne jusqu'aux huit antennes) à fin de transformer les données à un débit plus élevé et une portée plus longue, la technologie MIMO se base sur le phénomène de trajets multiple, où les données transmises affrontent des obstacles, puis se reçoivent par l'antenne selon différents angles et à des temps différents. Il consiste à envoyer les données par des codes différents sur chaque antenne de transmission, suivant un trajet différent des autres existants entre l'émetteur et le récepteur.

Cette dernière se base également sur le phénomène de diversité spatiale du milieu qui assure une dé-corrélation entre les divers trajets et ainsi permet la résolution de système d'équations du système MIMO, qui a une relation proportionnelle avec le nombre de codes qu'on puisse extraire du système d'équations de MIMO [9].

Le multi-trajet permet d'augmenter la capacité du système MIMO, en se basant sur la diversité spatiale, ce qui rend les communications plus fiables et le débit plus élevé [10].




Figure 3.1 Schéma Système MIMO

3.3 Principe de MIMO

Lors la propagation, le signal est exposé à des déformations, décalage temporelle où fréquentiels, par le canal due à le phénomène de propagation multi-trajets.

- diversité spatiale
- diversité fréquentielle : consiste à envoyer le même message sur des fréquences différentes.
- diversité temporelle : consiste à envoyer le même temps cohérence du canal.

3.4 Type MIMO

Selon le nombre d'antenne dans l'extrémité du système (émission, réception), on distingue quatre configurations (systèmes) :

- **SISO - Single Input Single Output**

On dispose d'une seule antenne en émission et d'une autre en réception.




Figure 3.2 Schéma Système SISO

- **MISO - Entrée multiple Sortie unique**

On installe plusieurs antennes à l'émission (diversité spatiale) et un seul à la réception, les signaux sont émis simultanément le même symbole d'énergie E_s/N_t par N_t antenne [11]. Donc la puissance d'émission est donnée par :

$$P = \sum P_i \dots (3.1)$$

P_i : est la puissance émise sur chaque antenne

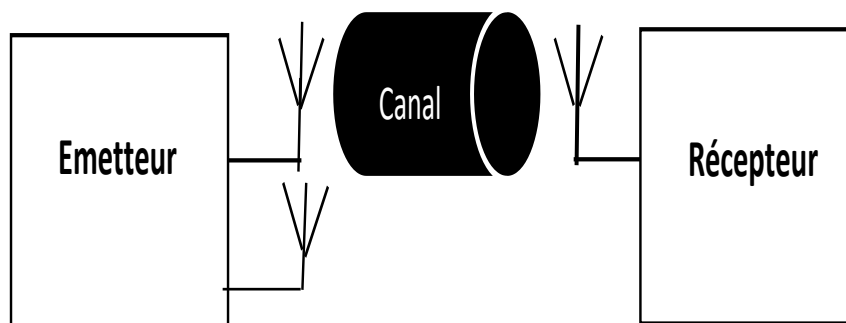


Figure 3.3 Schéma Système MISO

- **SIMO - Entrée unique Sortie multiple**

On installe plusieurs antennes à la réception et une à l'émission, pour éviter les déformations des signaux dû au canal [12].




Figure 3.4 Schéma Système SIMO

- **MIMO - Entrée multiple Sortie multiple**

Nous installons plusieurs antennes lors de la transmission et de la réception, permettant aux données d'être transmises sur plusieurs chemins, et cette technologie est un développement logique de l'ancienne technologie des antennes intelligentes pour améliorer la technologie sans fil. Les perturbations du canal sur le signal peuvent être éliminées en améliorant la qualité de ce dernier.




Figure 3.5 Schéma Système MIMO

3.5 Evolution de MIMO vers le MASSIVE MIMO

A été remarquer que plus le nombre d'antenne s'élève plus le domaine de couverture soit grand, ce qui fait une amélioration de performance de système, telle que les perturbations diminué, ainsi la disparation des interférences intracellulaires entre les utilisateurs.

L'utilisation de MIMO à grand échelle nous permet d'éviter le problème de spectre sans fil qui considéré cher et très occupé (notamment à 6GHZ), puisque ce dernier fournie un degré de liberté plus élevé en fonction de nombre d'antennes équipés.

Doter la station de base d'un grand nombre d'antennes offre de nombreux avantages qui améliorent à leur tour la communication sans fil. Cela a incité les scientifiques à équiper les bases de plus d'antennes, ainsi le concept est passé de MIMO à MASSIVE MIMO, afin de répondre aux besoins qui augmentent avec le nombre d'utilisateurs, donc le développement du système était nécessaire.

Le massif mimo est considéré comme un scénario MU-MIMO, où une station de base équipée d'un grand nombre d'antennes dessert plusieurs utilisateurs simultanément,

Ces études ont montré que le MIMO massif permet d'améliorer l'efficacité spectrale en diminuant la puissance de sortie rayonnée. Ainsi il est utilisé dans les bands inférieure à 6GHZ pour une évolution en douceur du LTE au pré-5G, et dans les bands à haute fréquence comme la transmission en ondes millimétriques.

Le massif mimo permet d'améliorer la couverture du réseau sans fil, la diminution de la puissance rayonnée des stations de base et des terminaux.

3.6 MASSIVE MIMO


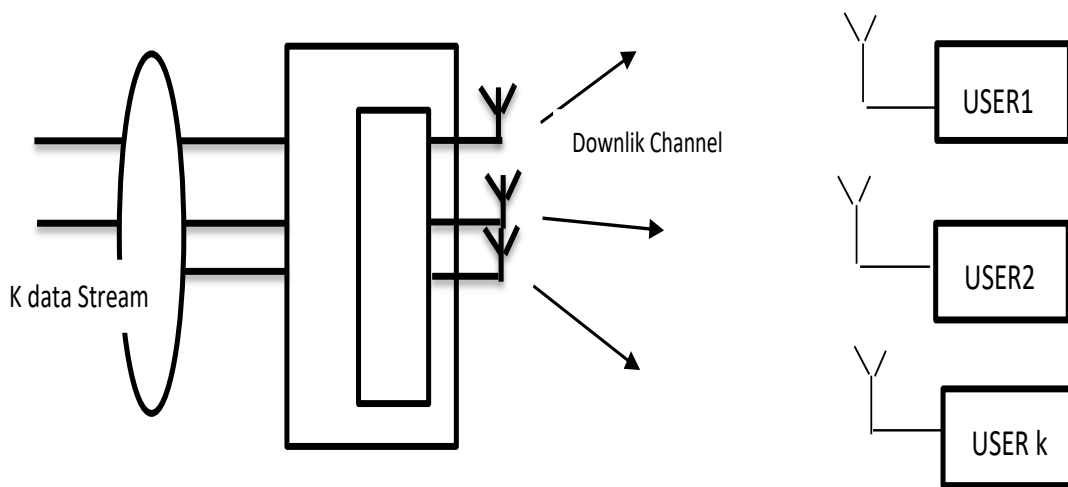


Figure 3.6 Une illustration de MIMO massive

MIMO massif ou Massive MIMO est une technologie de communication sans fil, qui peut offrir des réseaux large bande plus sécurisés, robustes, efficaces (en terme d'énergie et d'utilisation de spectre). Où les stations de base sont équipées d'un grand nombre d'antennes (une centaine à une millième), servant plusieurs utilisateurs (dix à cents) simultanément et dans la même fréquence [8], le modèle de base du MIMO massif est illustré à la **figure 3.7**



3.7 Modèle de base de MASSIVE MIMO

3.7 La Diversité Spatiale

La diversité spatiale est une technique utilisée pour augmenter le rapport signal sur bruit SNR, grâce au gain de diversité.

Il consiste à l'émission simultanée du même signal par plusieurs antennes d'émission, les signaux reçus sur chacune des antennes sont sommé cohéremment et remis en phase.

Il utilise le signal de l'antenne polarisée, qui reçoit le meilleur signal que les autres, où le gain de diversité fait augmenter le rapport signal sur bruit SNR.

3.8 Multiplexage spatial

Le multiplexage spatial est une technique utilisée pour améliorer l'efficacité spectrale, on augmente le débit de données de transmission [13], avec un SNR plus élevé.

Le manque de diversité des antennes impose l'affaiblissement de SNR qui rends le débit de transmission également faible donc le fonctionnement de ce dernier est mal, puisque le récepteur trouve des difficultés pour identifier les signaux non corrélés [14] [15].

3.9 Beamforming

Auparavant, la forme du faisceau d'énergie d'émission était de forme d'un cercle de 360°, ce qui signifie que l'énergie est égale dans toutes les directions, qui entraîne une grande consommation d'énergie et interférence entre les utilisateurs.

Alors que le Beamforming est une technique utilisée par le MASSIVE MIMO et même le MIMO pour focaliser l'énergie d'émission dans une direction spécifique, et donc l'énergie augmente vers l'utilisateur cible et diminue dans d'autres directions, ce qui entraîne une absence d'interférence entre les utilisateurs et moins de consommation d'énergie.

Dans le Beamforming, le faisceau d'énergie est confiné entre 3° et 30°, concentrant l'énergie dans un faisceau étroit qui lui permet d'atteindre une plus grande distance, c'est le principe de Beamforming.

3.10 Le canal de transmission :

Le canal de transmission est représenté par une matrice H de taille [Nombre d'antennes de Transmission * Nombre d'antennes de réception].

$$H = \begin{bmatrix} h_{11} & \dots & h_{Nt1} \\ \vdots & \ddots & \vdots \\ h_{2Nr} & \dots & h_{NtNr} \end{bmatrix}$$

Avec h_i représente le gain complexe du canal entre la jème antenne émettrice et l'ième antenne réceptrice.

La détermination de la matrice H est basée sur une technique connue sous le nom d'estimation de l'état de canal CSI.

3.11 Estimation du canal :

Le CSI est déterminé selon le mode de duplexage du système (TDD ou FDD)

3.11.1 Estimation du canal dans le TDD système :

Les canaux de la liaison montante et la liaison descendante sont alternés. Et utilisent le même spectre de fréquences, avec des tranches de temps différentes.

Le processus de l'entraînement nécessite un minimum d'utilisations du canal 2K.

On suppose que le canal reste constant sur T symboles. Ainsi, il faut que $2K < T$.


Chapitre 04

La Sélection d'Antenne AS

- **Dans la liaison montante** la BS a besoin de CSI pour détecter les signaux envoyés par l'utilisateur K, l'utilisateur K envoie des séquences pilotes orthogonales à BS sur la liaison montante. Ensuite La station de base estime les canaux sur la base des signaux pilotés reçus. Cela nécessite un minimum d'utilisations du canal K.
- **Dans la liaison descendante** la BS a besoin de CSI pour pré-coder les signaux transmet, Chaque utilisateur a besoin du gain de canal effectif pour détecter les signaux souhaités. Grâce à la réciprocité des canaux, le canal estimé à la BS dans la liaison montante est utilisé pour pré-coder les symboles de transmission.

La BS peut former des faisceaux pilotés et chaque utilisateur peut estimer les gains de canal effectifs sur la base des signaux pilotés reçus. Cela nécessite au moins K utilisations du canal.

L'estimation de canal dans le système TDD est présentée dans le schéma suivant :



3.11.2 Estimation du canal dans le FDD système

La liaison montante et Dans la liaison descendante utilise un spectre de fréquences différent, l'estimation du canal est ce fait selon le schéma de formation suivant :

- **Dans la liaison montante** la BS a besoin de CSI afin de pré-coder les symboles avant de les transmettre aux k utilisateurs. Les antennes de transmission à la BS émit N_t séquences pilotés orthogonales à k utilisateurs. Chaque utilisateur estimera le canal en fonction des pilotes reçus. Ensuite il renvoie en liaison montante ses estimations de canal à la station de base.
- **Dans la liaison descendante** la BS a besoin de CSI afin de décoder le signal transmit par K utilisateur, les k utilisateur transmettent k séquences pilotés orthogonales aux bs

. Ensuite, le bs estimera les canaux en fonction des signaux pilotés reçus. Ce processus nécessite au moins un utilisateur de canal k pour la liaison montante.

3.12 Massive MIMO préfère TDD Schéma

En mode FDD, l'estimation de canal repose sur le nombre d'antennes BS M . Par contre, en mode TDD, le temps d'estimation de canal est non biaisé de M . Dans Massive MIMO, M est grande, et par conséquent, le fonctionnement TDD est préférable. Par exemple, supposons que l'intervalle de cohérence soit $T = 200$ symboles (correspondant à un temps de cohérence de 1 ms et à une largeur de bande de cohérence de 200 kHz). Ensuite, dans les systèmes FDD, la quantité d'antennes BS et la quantité d'UT sont limitées par $M + K < 200$, tandis que dans les systèmes TDD, la contrainte sur M et K est $2K < 200$. On peut voir sur la figure 2.7 que la place FDD est beaucoup plus petite que la région TDD. Avec TDD, l'ajout d'antennes supplémentaires n'affecte plus les sources nécessaires à l'acquisition du canal.

3.13 Calcule de capacité

Le sujet porte sur le calcul de capacité, est donnée par :

$$C = \log_2(\det [I_{Nr} + \frac{\rho}{N_t} \cdot H \cdot H^*]) \text{ bps/hz} \dots (3.2)$$

Avec
$$\rho = \frac{P_s}{P_b} \dots (3.4)$$

D'après la formule de la capacité, il dépend de model de canal et la puissance totale émise est constante (3.1), donc la puissance est répartie sur chaque antenne d'émission (P/N_t).

3.14 Avantage de la technologie MASSIVE MIMO

D'après Chiang Ho, Meixiang Zhang et Renzheng Gao les principaux avantages de la technologie massive MIMO sont les suivants [16] :

1) La puissance de l'antenne est très faible :

Dans des conditions idéales, la puissance d'émission de chaque antenne est inversement proportionnel au nombre d'antennes, et sous certaines conditions de transmission du rapport signal sur bruit (SNR), la puissance d'émission totale est également inversement proportionnel au nombre d'antennes. Par conséquent, la puissance d'émission requise pour chaque antenne est inversement proportionnelle au carré du nombre d'antennes.

Cela peut réduire efficacement la consommation d'énergie dans les applications MASSIVE MIMO.

2) "hardening" des canaux :

Le nombre d'antennes tend vers l'infini, la matrice des canaux de La théorie de la matrice aléatoire peut être utilisée pour l'analyse de la valeur singulière de la matrice de canal serait distribution progressivement connue, et le vecteur de canal aura tendance à être orthogonal, le plus simple la méthode de traitement du signal est optimale.

3) Les effets du bruit thermique et du déclin à petite échelle sont éliminés

Utilisation d'un signal linéaire méthode de traitement, le bruit thermique et la décoloration à petite échelle affectent les performances du système augmente avec la diminution du nombre d'antennes, et l'effet de Le bruit et les évanouissements à petite échelle sont négligeables par rapport aux interférences entre zones.

4) Amélioration de la résolution spatiale

Dans les systèmes MIMO massifs, avec l'augmentation de la base antennes de station, la formation de faisceau peut transmettre les signaux transmis à un point de l'espace, c'est-à-dire que la station de base peut distinguer avec précision chaque utilisateur, améliorant ainsi l'espace résolution.

En résumé les avantages de système MASSIVE MIMO dans :

- 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

3.15 Efficacité Énergétique EE

L'efficacité énergétique d'un système de communication est donnée en bit/Joule, c'est le rapport entre le débit moyen (bit/seconde) et la consommation en puissance moyenne

PT (Watt=Joule/second). [17] Est définie par :

$$EE = \frac{\sum_{K=1}^K (E\{R_K^{(ul)}\} + E\{R_K^{(dl)}\})}{P_{Tx}^{(ul)} + P_{Tx}^{(dl)} + P_{CP}(M, K, \bar{R})} \dots (3.5)$$

Avec

$$E\{R_K^{(ul)}\} + E\{R_K^{(dl)}\} = R_K^{(ul)} + R_K^{(dl)} = (1 - \tau_{sum} \frac{K}{U}) \bar{R} \dots (3.6)$$

Et

$$\tau_{sum} = \tau^{(ul)} + \tau^{(dl)} \dots (3.7)$$

Tel que $\tau^{(ul)}$ $\tau^{(dl)}$ représentent les temps occupés par un symbole utilisé pour la signalisation en uplink et en downlink, U est le bloc temps/fréquence de cohérence et \bar{R} représente le débit.

$$\bar{R} = B \log(1 + \rho(M - K)) \dots (3.8)$$

$$P_{Tx} = P_{Tx}^{(ul)} + P_{Tx}^{(dl)} = B \sigma^2 \frac{\rho Sx}{\eta} K \sigma \dots (3.9)$$

ρ représente un paramètre proportionnel au rapport signal sur interférence (SINR).

B est la bande de fréquence,

σ^2 représente le bruit.

$Sx = Ex\{(l(x))^{-1}\}$ représente la distribution des utilisateurs et l'environnement de propagation.

η représente l'efficacité en puissance $0 < \eta < 1$.

Chapitre 04

La Sélection d'Antenne AS

P_{CP} représente la consommation en puissance due à la circuiterie, est la somme des puissances consommées par les différentes composantes analogiques et le traitement numérique du signal, donné par :

$$P_{CP} = P_{FIX} + P_{TC} + P_{CE} + P_{C/D} + P_{BH} + P_{LP} \dots (3.10)$$

P_{FIX} représente la consommation en puissance fixe utilisée pour le refroidissement de la circuiterie, les signalisations de contrôle, et les traitements en bande de base.

P_{TC} représente la puissance consommée par les composants de la circuiterie de chaque antenne à la station de base.

$$P_{TC} = MP_{BS} + P_{SYN} + KP_{UE} \text{ Watt} \dots (3.11)$$

P_{BS} représente la puissance de chaque antenne d'utilisateur UE.

P_{UE} représente la puissance consommée par l'oscillateur local P_{SYN} .

P_{CE} représente la consommation en puissance totale due au processus d'estimation de canal en uplink et en downlink.

$$P_{CE} = \frac{B}{U} (2\tau^{(ul)}MK^2)/L_{BS} + \frac{B}{U} (4\tau^{(dl)}MK^2)/L_{UE} \text{ watt} \dots (3.12)$$

$P_{C/D}$ représente la puissance requiert pour exécuter le processus de codage/décodage pour les deux cas uplink et downlink.

$$P_{C/D} = \sum_{K=1}^K (E\{R_K^{(ul)} + R_K^{(dl)}\}) (P_{COD}P_{DEC}) \text{ Watt} \dots (3.13)$$

P_{BH} représente la puissance nécessaire pour le transfert de donnée (uplink/downlink) entre la station de base et le core network.

$$P_{BH} = \sum_{K=1}^K (E\{R_K^{(ul)} + R_K^{(dl)}\}) P_{BT} \dots (3.14)$$

P_{LP} représente la puissance consommée par le traitement linéaire (pré-codage et détection).

$$P_{LP} = 2MKB \left(1 - \frac{K}{U} (\tau^{(ul)} \tau^{(dl)})\right) + P_{LP-C} \dots (3.15)$$

P_{LP-C} est calculé selon l'algorithme utilisé en uplink pour la détection et en downlink pour le pré-codage, le cas de Forcing.

$$P^{(ZF)}_{LP-C} = \frac{B}{U} [(K^3/L3_{BS}) + (MK + 3MK^2/L_{BS})] \text{ watt est consommée.} \dots (3.16)$$

3.16 Efficacité Spectrale

L'efficacité spectrale permet de juger de la bonne ou mauvaise utilisation que l'on fait de la bande passante du canal.

Dans les systèmes MASSIVE MIMO, Afin d'obtenir une efficacité spectrale maximale (SE), les chercheurs ont étudié le nombre optimal d'utilisateurs réguliers pour un créneau horaire. Sachant que dans la pratique, on ne peut pas négliger la contrainte de la qualité du service (QoS), tel que La relation entre le SE efficace, la contrainte QoS et le nombre d'utilisateurs réguliers est formulée comme une fonction continue.

La probabilité de violation du délai est considérée comme un critère QoS important qui dépend de la stabilité de la transmission sur une longue période plutôt que du taux de transmission instantané d'un créneau horaire. [18] L'analyse de l'SE efficace réalisable d'un système MASSIVE MIMO est fait sous la contrainte de probabilité de violation de retard, avec la théorie de la capacité effective (CE) des canaux sans fil, [18] associe la probabilité de violation des retards aux fluctuations du taux de transmission causées par la stratégie Massive MIMO.

L'efficacité spectrale est définit par le nombre de bits pouvant être transmis par unité de bande passante Elle se mesure

$$SE = \frac{R}{B} \left(\frac{\text{bit}}{\text{s}}\right) / \text{Hz} \dots (3.17)$$

Théorème 1 : Si une estimation de canal MMSE est utilisée, la capacité de canal ergodique UL de UE k dans La cellule j est délimitée par :

La cellule j est délimitée par SE_{jk}^{UL} :

$$SE_{jk}^{UL} (\tau_u/\tau_c) E\{\log_2 1 + SINR_{jk}^{UL}\} \frac{\text{bit}}{\text{s}} / \text{Hz} \dots (3.18)$$

Théorème 2 : La capacité de canal ergodique DL d'UE k dans la cellule j est délimitée par SE_{jk}^{DL} :

$$SE_{jk}^{DL} = (\tau_D/\tau_C) \log_2 1 + SINR_{jk}^{DL} \dots (3.19)$$

$$\tau_C = \tau_C + \tau_u + \tau_d \dots (3.20)$$

Avec

τ_c Le temps de cohérence

τ_p Signaux pilote UL

τ_u Signaux de données UL

τ_d Signaux de données D

3.17 Utilité de MASSIVE MIMO pour la 5G

L'efficacité spectrale est importante pour répondre au besoin de la 5G, aussi la précision millimétrique et l'efficacité énergétique, ce qui rend le 5g demande des spectres hauts fréquence.

La seule et la meilleure technique qui peut fonctionner à des fréquences inférieure à 6GHz c'est le MASSIVE MIMO, cette dernière bande étant déjà plein à craquer, l'efficacité spectrale supérieure du massive mimo en fait le candidat idéal.

Aussi, l'utilisation d'un grand nombre d'antenne permet aux réseaux de servir un plus grande d'utilisateur, avec une efficacité et fiabilité.

3.18 Conclusion

Dans ce chapitre on a présenté les systèmes MIMO, Ensuite Les systèmes Massive MIMO, qui consiste à équiper les BS par un très grand nombre d'antenne, afin de fournir un débit et une efficacité spectrale beaucoup plus élevée qu'avec le MIMO, aussi les différentes techniques qui base ces deux derniers. Ainsi nous avons décrit l'efficacité spectrale et l'efficacité énergétique obtenue par le MASSIVE MIMO.

4.1 Introduction

La technologie MIMO massif a promis d'améliorer L'EE, ES...Etc. comme est présent en dessous, mais d'autre part a exigé que le nombre de chaines radio fréquence (RF) soit égale au nombre d'antennes ce qui impose le problème de complexité de matérielle de système, pour résoudre ce problème en utilise une technique de traitement de signal la sélection d'antenne.

4.2 La Méthode de Sélection d'Antenne AS

La sélection d'antenne est une technologie de traitement du signal qui peut réduire considérablement la complexité des systèmes multidimensionnels MIMO (entrées multiples sorties multiples), Telle qu'elle réduire le nombre de chaînes de radiofréquence nécessaires en activant uniquement un sous-ensemble des antennes disponibles dans chaque intervalle de transmission [20].

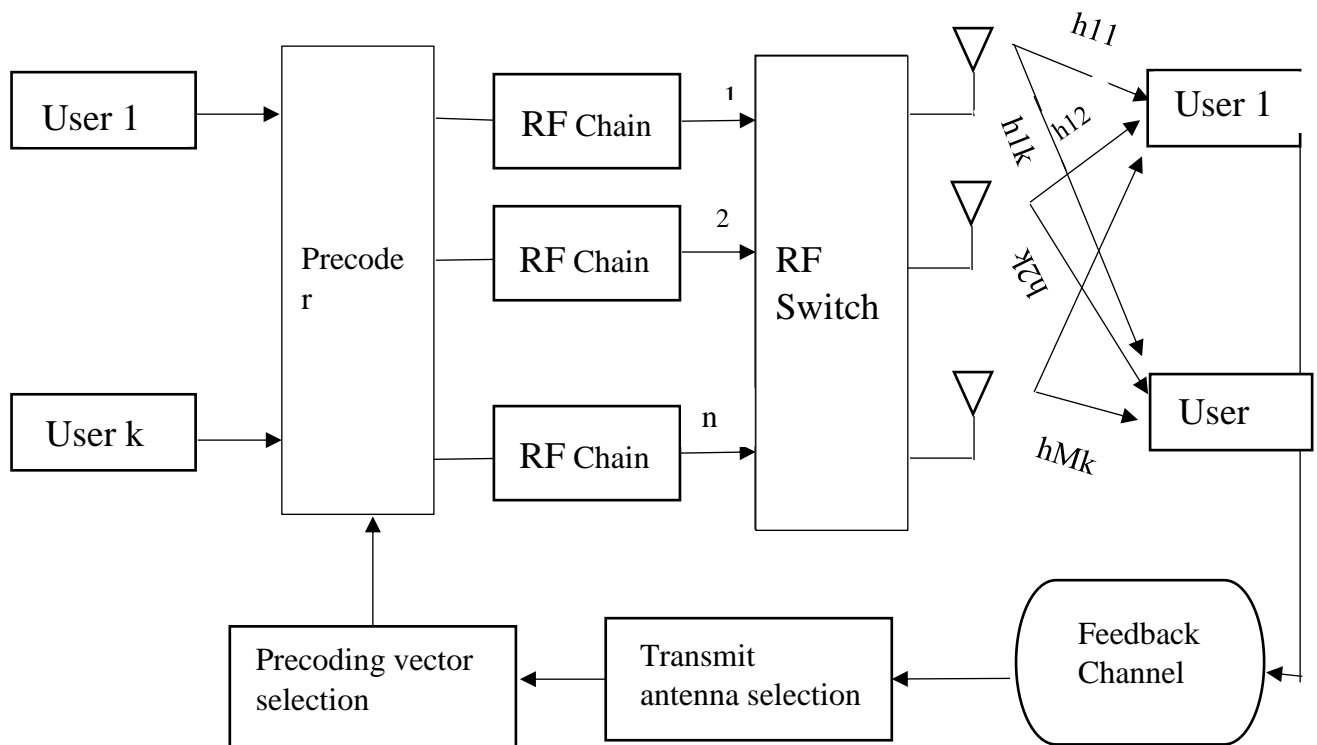


Figure 4.1 schéma présentatif de la méthode de selection d'antenne

4.3 Les méthodes approuvées par La Sélection d'Antenne

Il existe deux types de méthode pour trouver le sous-ensemble des antennes optimales, les méthodes basées sur l'optimisation et les méthodes basées sur les données

4.3.1 optimization-driven méthodes

Les méthodes basées sur l'optimisation consiste à sélectionné un sous ensemble d'antenne selon le type de communication, tel que la capacité, taux d'erreur sur bit ... il est basée sur la méthode relaxation convexe comme solution au problème de sous optimisation, celle-ci dépend des points initiaux et détermine alors facilement l'optimum local.

Par contre, les problèmes de SA sont toujours non convexes, en plus la complexité du calcul dans les algorithmes de relaxation convexe, ils font que ce dernier ne convient pas à la AS en temps réel [21].

Il existe deux méthodes pour trouver les labels optimaux pour les modèles non linéaires :

- **Les méthodes basées sur les algorithmes traditionnels de statistique :**

C'est algorithmes peuvent être calé ou tomber en panne, dans le cas où on a de nombreuses

Variables à optimiser ou le modèle Est non linéaire, A cause de l'énorme charge de calcul. [22],

A affirmé que ces derniers sont Inutiles pour trouver des conceptions non standard.

- **Les méthodes basées les algorithmes CVX :**

C'est l'utilisation des algorithmes basés sur CVX, sont très rapides et flexibles

Pour trouver des conceptions optimales [23].

4.3.2 data-driven méthodes

Les méthodes basées sur les données appliquent les techniques de machine Learning supervisé sur le Big data. On utilise les k-plus proches voisins (KNN) et la machine à vecteurs de support (SVM) qui sont très outil dans les problèmes d'exploitation des données, pour classifie des données du canal suffisant afin de déterminer le sous-ensemble d'antenne sélectionné.

Ces méthodes ont moindre coût du calcul dans la phase de test et sont plus pratiques à utiliser dans une application réelle.

4.4 La méthode d'optimisation convexe

CVX est un système de modélisation conçu pour résoudre des problèmes d'optimisation Convexe [24], qui est disponible dans MATLAB. CVX peut résoudre de Nombreux types de problèmes d'optimisation, la programmation linéaire et Quadratique, la programmation de cône de second ordre, programmation semi-définie Complexes. Avec différents Algorithmes [25], comme Descente la plus raide, méthodes de Newton pour les problèmes de minimisation sans Contrainte et avec contraintes d'égalité, méthodes des points intérieurs pour les Problèmes de minimisation sous contraintes d'inégalité. $\gamma \epsilon$

On considère la méthode de point intérieurs, l'équation de problème de minimisation par contraint d'égalité :

$$\begin{aligned} \min g_0(V) \text{ subject to :} \\ \mathbf{g}_1(V) \leq 0 \\ \mathbf{g}_2(V) \leq 0 \\ AV = \mathbf{b} \end{aligned} \quad \dots (4.1)$$

Avec : $V = (V_0 \dots V_{k_0})$

A : matrice de $l_0 \times k_0$

$\mathbf{g}_0, \mathbf{g}_1, \mathbf{g}_2$: fonction convexe.

Etape 01 :

Transformer (4.1) en (4.2), problème de constraint d'égalité par une fonction de barrière

$$\begin{aligned} \min g_0(V) - \frac{1}{\delta} \sum_{i=1}^2 \log(g_i(V)) \\ \text{subject to : } AV = \mathbf{b} \end{aligned} \quad \dots (4.2)$$

Etape 02 :

Il existe une séquence de problèmes dans l'équation (4.2) définie par une augmentation suite de $\delta: 0 < \delta(0) < \delta(1) < \delta(2)$

- Si δ est fixé on peut résoudre (4.2) par la méthode de Newton

- Sinon avec une approche de suivi de chemin ou approche de barrière On prend le point de départ de (4.2)

$$\delta = \delta(j + 1), j = 1, 2, \dots$$

Les problèmes d'optimisation convexe doivent être écrits sous certaines formes avant de pouvoir être résolu par CVX. On décrit quelques critères de conception optimale couramment utilisés et comment ils peuvent être formulés de manière à ce que CVX puisse les optimiser

Critère d'optimisation :

Il existe plusieurs critères d'optimisation : A-, As-, c-, I- L- et D-optimalité, chaque critère peut être formulé comme une fonction convexe.

On donne un modèle statistique, la distribution des erreurs et un espace de conception discrétisé, $SN = \{x_1, \dots, x_N\}$,

Un plan approché sur SN est définie par

$$\xi_N = \{(x_i, w_i), i = 1, \dots, N\}$$

Avec le vecteur poids en ces points, $w = (w_1, \dots, w_N)^T$, satisfait :

$$w_i \geq 0, i = 1, \dots, N, \sum_{i=1}^N w_i = 1 \dots (4.3)$$

On considère le critère D-optimalité, qui est le critère le plus utilisé on minimise la fonction objectif.

$$\mathcal{L}'_D(\xi_N) = -\log(\det(I_{\xi_N}(\theta))) \dots (4.4)$$

$$\mathcal{L}'_D(\xi_N) = -(\det(I_{\xi_N}(\theta)))^{1/q} \dots (4.5)$$

Le problème d'optimisation consiste à déterminer les points de SN qui reçoivent un poids positif et devenir des points d'appui de la conception optimale.

$$\mathcal{L}_{AC}(\xi_N) = \text{trace}(C^T I_{\xi}^{-1}(\theta) C) \dots (4.6)$$

Le critère d'optimisation est défini par la matrice $q \times l$, on écrit les problèmes d'optimisation sous la forme générale :

$$\min \mathcal{L}(\xi_N), \quad \text{subject to: } w_i \geq 0, i = 1, \dots, N, \sum_{i=1}^N w_i = 1 \dots (4.7)$$

Les algorithmes de CVX détaillé sont représentés dans [22]

4.5 Optimisation de l'efficacité énergétique par la AS

Lorsque on fait passer le MIMO massif de la théorie à la pratique, l'un des principaux défis est la complexité du système, car le nombre d'antennes de station de base et de chaînes radiofréquence (RF) associées se comptent par centaines. Parallèlement à la complexité du système, la consommation d'énergie du matériel peut augmenter de manière significative, ce qui remet en question l'efficacité énergétique globale du MIMO massif.

On sait bien que la sélection d'antennes fait minimiser le nombre de chaîne radio fréquence active, ce qui permet couramment de minimiser la consommation d'énergie.

4.6 Conclusion

La méthode de sélection d'antennes est une méthode très utile dans les systèmes MASSIVE MIMO, il permet de réduire la complexité matérielle de cette dernière afin d'optimiser leurs performances, on minimise le nombre de chaînes radio fréquences utilisées, la AS basé sur deux méthodes différentes, les méthodes d'optimisation convexe et les méthodes basées sur les données, tel que les méthodes basées sur les données sont meilleures que celles basées sur l'optimisation.

5.1 Introduction

La méthode de sélection d'antenne pour trouver le sous-ensemble d'antennes optimal, consiste à comparer toutes les combinaisons possibles par une recherche exhaustive, ce qui demande une grande quantité de calculs et prend beaucoup de temps vu que le système MASSIVE MIMO a des données à grand échelle. Tandis que les technique d'apprentissage profond DL ont connu une grande importance pour l'analyse de données à grand échelle [28], aussi le CNN a une révolution dans le domaine de classification tel que la classification des images, les textes, les vidéos et même dans le domaine de communication sans fil [30].

La matrice de canal est une donnée structurée et de grande dimension, le même cas pour la classification multi-classe et multi-label ML où les entrées ont également des dimensions élevées et beaucoup de texte, ce fait nous inspiré à adopter la matrice de canaux de CNN et introduire les techniques DL dans le domaine de la sélection d'antenne.

5.2 Définition de l'apprentissage profond (Deep Learning)

Le Deep Learning ou l'apprentissage profond, est un sous-ensemble de Machine Learning qui regroupe les méthodes les plus efficaces et les plus performantes appliquées dans la communauté de l'apprentissage automatique [29].

L'apprentissage automatique, consiste à développer un modèle en servant d'un algorithme d'optimisation qui analyse un ensemble de données pour minimiser les erreurs entre les données prédicats et les données réelles, dans le but de tirer des règles qui permettront de tirer des conclusions sur de nouvelles données.

L'apprentissage profond est basé sur l'analogie, consiste à développer des réseaux de neurones artificiels, composés d'au moins deux couches (fonctions, neurones) effectuent des tâches spécifiques, telle que les résultats de chaque couche est considéré comme des entrées pour la couche qu'il suit.

Plus les réseaux sont profonds, c'est-à-dire plus ils contiennent de fonctions, plus la machine apprendra à effectuer des tâches complexes, telles que la reconnaissance d'objets, la conduite de machines, etc.

5.3 Principe

5.3.1 Le perceptron

Le perceptron est l'origine des réseaux de neurones modernes, c'est un algorithme de classification présenté par une fonction de décision f , leur entrée est un vecteur $x=[x_1, x_2, \dots, x_n]^T$ et leur sortie est un scalaire y qui permet d'identifier la classe d'appartenance de l'entrée x , est utilisé pour les problèmes de classifications binaires[31].

La fonction f est passée par deux principales étapes :

- Pré-activation : c'est la combinaison linéaire de l'entrée x avec le vecteur de poids $w = [w_1, \dots, w_n]^T$, avec $a(x) = w^T x$.
- Activation h : c'est la sortie de la pré-activation en lui ajoutant le terme de biais b et donne en sortie y avec, $y = h(a(x)) = h(w^T x + b)$.

On désigne le vecteur des paramètres par θ , tel que $\theta = [b, w_1, \dots, w_n]$.

$$D'où : y = f(x; \theta) = h(a(x)) = h(w^T x + b).$$

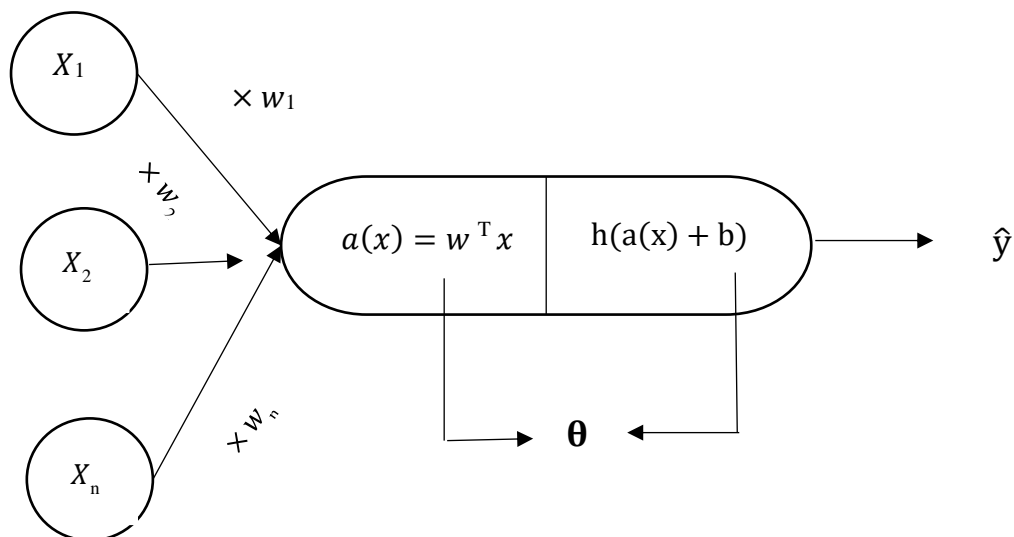


Figure 5.1 Le perceptron

5.3.2 Perceptron multi-couches MLP

C'est un réseau de neurones, consiste à un algorithme de classification, utilisé pour les problèmes le plus complexes comme la classification multi-classes ML, est composée de plusieurs perceptrons ou neurones artificiels.

L'entrée $x(t)$ est transformé par les couches cachées jusqu'à la dernière couche (couche de sortie). Les couches cachées sont reliées entre elles, et chaque sortie de couche correspond à une autre couche qu'il suit, la procédure de fonctionnement des neurones de chaque couche est la même que le perceptron simple.

Le MLP est aussi passé par deux étapes :

- La pré-activation :

$$a^{[k]}(x(t)) = W^{[k]} h(a^{[k-1]}(x(t))) + b^{[k]} \dots (5.1)$$

- Activation :

$$f^{[k]}(x(t); \theta^{[k]}) = h^{[k]}(a^{[k]}(x(t))) \dots (5.2)$$

Avec :

$w^{[k]}$ est une matrice de taille $(n \times m)$, avec m est le nombre de neurones de la couche $k-1$, n est le nombre de neurones de la couche k , chaque ligne consiste à un vecteur w des poids de chaque neurone de la couche.

$b^{[k]}$ est un vecteur des biais des neurones de la couche k .

Le vecteur des paramètres est donné par :

$$\theta = W^{[1]}, b^{[1]}, \dots, W^{[k]}, b^{[k]}, \dots, W^{[L]}, b^{[L]}$$

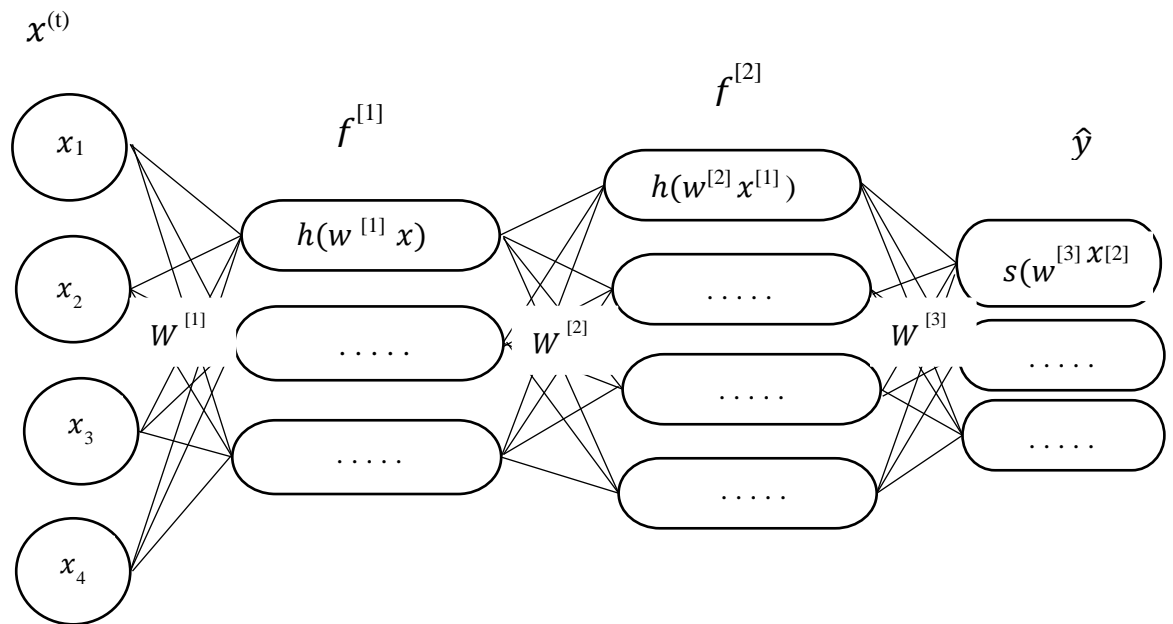


Figure 5.2 L e perceptron multi-couches.

5.3.3 L’entrainement

La phase d’entrainement est une phase principale pour les réseaux de neurones, consiste à déterminer les paramètres θ , afin que la fonction f puisse identifier correctement les classes pour leurs entrées $x^{(t)}$.

Les données de l’entrainement x_{train} correspondent à 60% de données totale, regroupant une sélection aléatoire de vecteurs de X tels que $x_{\text{train}} = x^{(1)}, \dots, x^{(n_{\text{train}})}$, et ensemble de labels qui définit la classe de chaque vecteur $y_{\text{train}} = y^{(1)}, \dots, y^{n_{\text{train}}}$

On utilise les couples entrée-label $\{x^{(t)}, y^{(t)}\}$ pour trouver la relation entre une entrée et sa classe, ce qui permet donc de résoudre les problèmes de classification.

On peut déterminer θ par une minimisation du risque empirique sur les prédictions du modèle sur x_{train} à travers la fonction de coût/perte \mathcal{L} loss-function :

$$\arg \min_{\theta} J(x^{(t)}, y^{(t)}; \theta) \dots (5.3)$$

Avec :

$$\mathcal{L}(x^{(t)}, y^{(t)}; \theta) = \frac{1}{\text{card}(x_{\text{train}})} \sum_t E(f(x^{(t)}; \theta), y^{(t)}) \dots (5.4)$$

La tâche de l'entraînement correspond à minimiser itérativement la fonction de perte \mathcal{L} , on mesure par la fonction d'erreur E l'écart entre la prédiction du modèle et le label attendu sur les données d'entraînement (réelles) à travers un algorithme que l'on appelle la rétro-propagation backforwerd.

L'entraînement est influencé par plusieurs hyperparamètres.

L'entraînement par rétro-propagation :

Descente de gradient GD :

La GD est un algorithme d'optimisation utilisé pour la rétro propagation d'erreur, afin de mettre à jour itérativement les poids, en utilisant le gradient de la fonction de coût \mathcal{L} sur les données de x_{train} [32], on soustrayant à chaque poids du réseau la grandeur $\mathcal{L}_{\text{train}}(f(x^{(t)}; \theta))$, on fait tendre de façon itérative la valeur ce dernier vers un minimum.

Alors les itérations de GD sur les données d'entraînement permet de modifier les valeurs des poids afin d'améliorer la performance du réseau, la GD fait un passage complet sur x_{train} ce qu'on appelle époque, ces deux derniers on les appels des hyperparamètres.




Figure 5.3 le principe de la rétro propagation pour l'entraînement des réseaux de neurones.

Avec ϵ : c'est l'un des hyperparamètres appelé le taux d'apprentissage. Il détermine l'amplitude des étapes de la GD, compris entre 1 et 10^{-6} [33].

5.3.4 Validation

Le but de l'entraînement est d'utiliser la relation trouvée entre x_{train} et y_{train} sur de nouvelles données, pour cela la validation permet de juger la qualité de cet entraînement, on dispose pour l'entrée un nouveau sous ensemble des données x_{valid} et des labels y_{valid} associés aux éléments de x_{valid} .

Les données de x_{valid} sont mises à l'écart et utilisées que pour évaluer la fonction de \mathcal{L} sur x_{valid} entre chaque étape de la GD pour déterminer la performance du modèle sur de nouvelles données. On appelle ce dernier $\mathcal{L}_{\text{valid}}$.

5.3.5 Evaluation la qualité de l'entraînement

La qualité de l'entraînement est dépendre de deux conditions suivant [34] :

- $\mathcal{L}_{\text{train}}$: doit décroître et converge vers le zéro.
- $\mathcal{L}_{\text{valid}}$: L'écart $|\mathcal{L}_{\text{train}} - \mathcal{L}_{\text{valid}}|$ doit être faible.

Lorsque les valeurs de $\mathcal{L}_{\text{train}}$ et $\mathcal{L}_{\text{valid}}$ décroître conjointement, on dit que les prédictions du réseau de neurones se rapprochent des labels attendus sur des données différentes de x_{train} , alors le modèle généralise bien sur les nouvelles données de x_{valid} .

Lorsqu'une des deux conditions n'est pas respectée on se trouve dans l'un des phénomènes suivant :

- Sous-apprentissage : c'est une stagnation de $\mathcal{L}_{\text{train}}$ et $\mathcal{L}_{\text{valid}}$, lié au choix de l'algorithme d'optimisation ou même à la structure du réseau que nous cherchons à optimiser, signifie que la capacité de réseau est insuffisante, on peut résoudre ce problème par l'ajout des couches de neurones ou en agrandissant les couches existantes.
- Sour-apprentissage : où $\mathcal{L}_{\text{train}}$ décroît pendant l'entraînement mais $\mathcal{L}_{\text{valid}}$ qui ré-augmente après avoir décré pendant quelques époques, lié au processus d'optimisation et au choix des paramètres, la décroissance de $\mathcal{L}_{\text{valid}}$ montre que les sorties du modèle ne sont pas correctes pour des données que x_{train} . Alors le modèle ne généralise pas.

5.4 Réseaux de neurones convolutifs CNN

C'est l'un des architecteurs de réseaux de neurones le plus performants pour les problèmes de classification images et la classification multi-labels, est caractérisée par l'ajout de couches de convolution en remplacement ou en complément de couches de neurones entièrement connectées présentes dans les MLP.

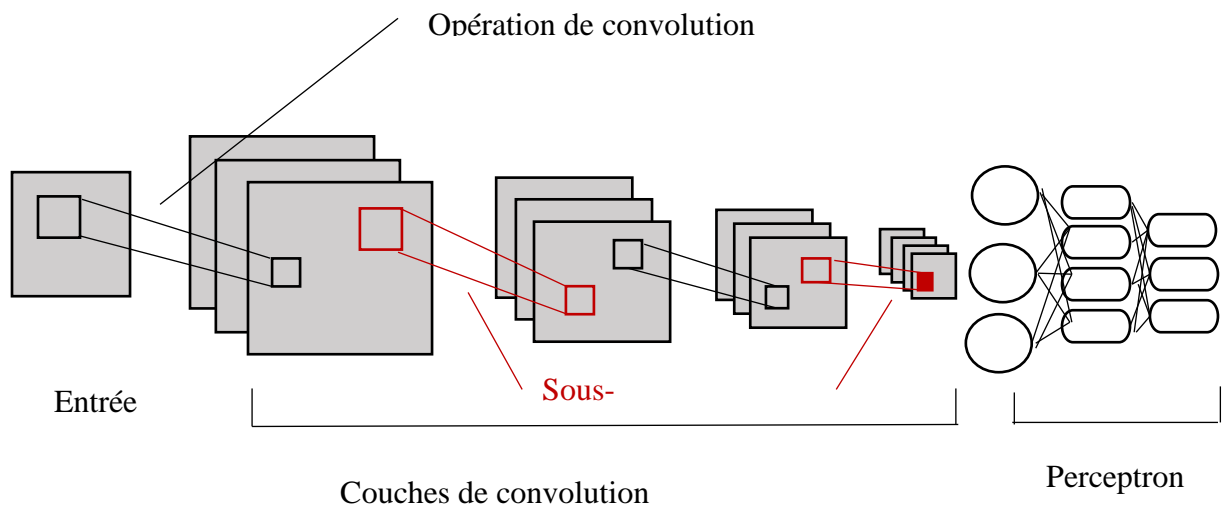


Figure 5.4 Architecteur d'un CNN

5.5 Structure des CNN

Les Réseaux de neurones convolutifs CNN sont composés de plusieurs couches :

- Convolutional layers :
- Pooling layers
- Fully connected layers

La couche de convolution

L'opération de convolution est définie comme par :

$$(f * g)(x) = \sum_t f(t)g(x + t) \dots (5.5)$$

Les convolutions 2D, pour les images est définie par :

$$(K * I)(i, j) = \sum_{m, n} K(m, n)I(i + n, j + m) \dots (5.6)$$

Avec k est le noyau de convolution appliqué sur l'image I.

Cette couche est caractérisée par trois hyperparamètres pour dimensionner le volume de sortie :

- La profondeur : c'est le nombre de noyaux de convolution.
- Le pas : contrôle le chevauchement des champs récepteurs.
- La marge à 0 ou zero-padding : permet de contrôler la dimension spatiale du volume de sortie de taille p. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée [35].

Le principe de la convolution 2D est un glissement d'un noyau (filtre) de taille $k \times k$ sur une image I , par un nombre de pixels s "stride". On obtient la convolution entre le noyau et la partie de l'image traitée.

On applique des filtres C_0 sur une image de taille $W_i \times H_i \times C_i$ (W_i la largeur, H_i la hauteur et C_i le nombre de canaux, généralement $C_i = 3$), on résulte à la sortie image de taille $[W_0 \times H_0 \times C_0]$.

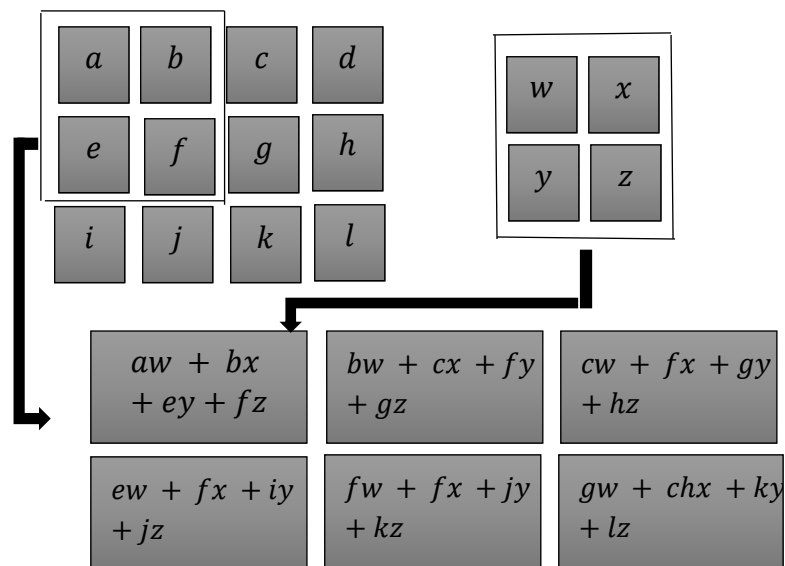


Figure 5.5 principe de convolution

Avec :

$$W_0 = \frac{W_i - k + 2p}{s} + 1$$

$$H_0 = \frac{H_i - k + 2p}{s} + 1$$

La convolution de l'image I avec le filtre Kl est donnée par :

$$kl * I(i, j) = \sum_{c=0}^2 \sum_{n=0}^2 \sum_{m=0}^4 Kl(n, m, c) I(i + n - 2, i + m - 2, c) \dots (5.7)$$


On suppose que l'image à 3 canaux et, $Kl = (l = 1, \dots, C_0)$ désigne $5 \times 5 \times 3$ noyaux (où 3 nombre de canaux de l'image d'entrée).

La couche de Pooling

L'opération permet à de réduire la dimension de l'image d'enté, en prenant la moyenne ou le maximum sur des patches de l'image, il travaille sur des petits patches de l'image.

On suppose un 2×2 patch, tel qu'on prend la valeur maximale pour définir la couche de sortie, et un stride $s = 2$, on divise par 2 la largeur et la hauteur de l'image.

On réduisant ainsi la quantité de paramètres et de calcul dans le réseau. Il est donc important d'insérer périodiquement une couche de Pooling entre deux couches de convolution



successives.

Figure 5.6 principe de Pooling

La Couche entièrement connectée(FC)

On ajoute la couche d'entièrement connectée FC après plusieurs couches de convolution et de max-Pooling, où les neurones ont des connexions vers toutes les sorties de la couche précédente, en sortie de ces couches est transformé en vecteur puis nous ajoutons plusieurs couches de perceptron.

Leurs fonctions d'activations peuvent donc être calculées avec une multiplication matricielle suivie d'un décalage de polarisation.

Couche de perte (LOSS)

La couche de perte ou la fonction de perte est une mesure qui définit comment l'entraînement du réseau pénalise l'écart entre le signal prévu et réel, il existe plusieurs fonctions de perte :

- La perte Soft max : est utilisée pour prédire une seule classe parmi K classes mutuellement exclusives.
- La perte par entropie croisée sigmoïde : est utilisée pour prédire K valeurs de probabilité indépendante dans $[0,1]$. C'est la fonction de perte que nous avons utilisé dans notre travail.
- La perte euclidienne : est utilisée pour régresser vers des valeurs réelles.

5.6 Les problèmes de classification

La classification consiste à catégoriser des éléments parmi plusieurs classes ou familles d'objets, Il s'agit d'automatiser le processus afin d'étiqueter le document textuel comme étant un texte parlant des avions, des animaux ou de science. Lorsque processus de traitement est appris, on peut utiliser le modèle pour catégoriser automatiquement une nouvelle donnée.

La classification est un processus d'apprentissage statistique de but consiste à identifier une classe y à des exemples x représentés par un vecteur x . Chaque exemple x_i est associée à une classe y_i , Tel que $y_i \in L$, $L = \{l_k\}$ avec $k \in [1, K]$ (K le nombre de classes du problème).

Lorsque processus de traitement est appris, on peut utiliser le modèle pour catégoriser automatiquement une nouvelle donnée.

On définit Le problème d'optimisation par la forme générale comme une minimisation du risque associé théorique de classification :

$$h^* = \arg \min_h R(h) \dots (5.8)$$

$$R(h) = \int h(x) \neq y) dP(x, y) \dots (5.9)$$

Dans notre travail on définit les classe par le nombre antennes de transmission, donc on a N_t classe qui peut atteindre jusqu'à des millions de classe.

Habituellement, le schéma de modèle multi-classes Il s'agit simplement d'apprendre une fonction de score pour chaque classe. Lors de la classification d'un nouvel exemple, il suffit de calculer le score de chaque classe pour cet exemple. L'algorithme prédit ensuite la classe ayant obtenu le meilleur score. Le choix de la fonction de score est libre.

5.5.1 Les différents types de classifications

- **Classification binaire :**

Est utilisée dans le cas où il n'y a que deux classes distinctes et que les données que nous voulons classer identifient exclusivement par l'une de ces classes.

Le schéma de classification consiste à utiliser un classifieur binaire, Il s'agit d'apprendre une fonction de score pour chaque classe. Lors de la classification d'un

Nouvel exemple, il calcule le score de chaque classe pour cet exemple. L'algorithme prédit ensuite la classe ayant le meilleur score. Le choix de la fonction de score est libre.

- **Classification multi-classe ou single-labels SL :**

Est utilisée dans le cas où il y a trois classes ou plus et que les données que nous voulons classer identifie exclusivement par l'une de ces classes.

Les schémas de classification multi-classes classiques sont constitués d'un ensemble de classifieurs binaires simples combinés pour former un classifieur plus complexe, il consiste à faire des combinaisons binaires entre tous les étiquettes.

- **Classification multi-labels ML**

Est utilisée dans le cas où 'il y a deux ou plusieurs classes et que les données que nous voulons classer peuvent n'appartenir à aucune des classes ou à toutes simultanément. C'est aussi le cas où on veut étiqueter par 0 ou 1, des éléments déjà étiquetés.

On utilise un ensemble de classifieurs multi-classe, tel que chaque classifieur prédire une étiquette pour une donnée, ensuite on combine les prédictions par ce qu'on appelle la méthode d'ensemble, on résulte un pourcentage de prédiction pour chaque labels, on vote sur ce dernier selon le seuil de discrimination (threshold).

5.5.2 Limite de classification multi-classe

Les schémas de classification multi-classe ou classification à étiquette unique comme OAA exigent d'apprendre un classifieur binaire simple par classe et faire tous les combinaisons possibles entre les classes disponibles.

Dans notre cas on considère que le nombre de classe est le nombre des antennes de transmission N_t , qui peut atteindre jusqu'à des millions de classe, la considération que notre cas est un problème de classification multi-classe, est logiquement impossible, car c'est une opération coûteuse et prend un temps qui évolue avec le nombre de classe. De ces raison on a classifie notre cas comme un problème de classification multi-labels tel que les labels sont étiquetés par N_t classe ensuite par les classe 0 ou 1.

5.7 Conclusion

Dans ce chapitre, nous avons pu collecter divers concepts et connaissances sur les techniques d'apprentissage profond DL, l'architecteur CNN, les problèmes de classification SL et ML, et les projeter sur notre modèle afin que nous puissions les appliquer à notre méthode ML-CNN dans la partie suivante.

Partie Pratique Et Simulation

6.1 Introduction

Le but de ce travail est d'optimiser les performances d'un système MIMO Massif en Exploitant une technique de sélection d'antenne à complexité réduite. Les techniques d'apprentissage par machine ont été récemment proposées pour résoudre des problématiques différentes dans les systèmes de communications sans fil. Pour cela, on propose d'exploiter un réseau de neurone convolutionnel (CNN) capable de retrouver la combinaison d'antenne optimale qui offre la capacité maximale du système. Dans ce chapitre, on va présenter le modèle du système utilisé, description des algorithmes exploités et les résultats obtenus.

6.2 Modèle du système

On considère une Station de Base équipée de N_t antennes d'émission pour servir N_r usagers a antenne unique La matrice de Channel est noté par :

$H = [h_{ij}] \in \mathbb{C}^{N_t * N_r}$, telle que h_{ij} sont les coefficient d'atténuation et de déphasage entre le jème antenne d'émission et le ième antenne de réception.

Le signal d'émission est donnée par :

$$t(k) = [t_1(k), t_2(k), \dots, t_{N_t}(k)]$$

Le signal de réception est donnée par :

$$r(k) = [r_1(k), r_2(k), \dots, r_{N_r}(k)]$$

Le Bruit Blanc Gaussien est donnée par :

$$w(k) = [w_1(k), w_2(k), \dots, w_{N_r}(k)]$$

Dans une communication sans fil, les signaux transmis subissent des déformations. Par conséquent, les signaux reçus seront complètement différents de ceux de l'émission. La matrice H fournit une description de déformation.

Donc, le signal à la réception est donné par :

$$r(k) = \sqrt{\frac{\rho}{N_t}} H * t(k) + w(k) \quad (\rho = \text{SNR})$$

6.3 Sélection d'antenne

La méthode de sélection d'antenne a été proposée pour pallier le problème de la consommation énergétique dans les systèmes MIMO massif. Elle consiste à réduire le nombre des chaînes radio fréquence associées à chaque élément d'antenne en choisissant

Un sous-ensemble d'antenne parmi N_t antennes (antenne active = RF active) disponibles à la station de base périodiquement à chaque intervalle de temps de transmission. Basé sur le critère de maximisation de la capacité du canal.

Soit $B \in \mathbb{C}^{N_t \times N_r}$ la matrice de canal partielle, dont les colonnes sont sélectionnées à partir de la matrice de canal d'origine H .

La fonction objective à maximiser est donnée par :

$$\max_B C(B) = \log \det \left(I_{N_r} + \frac{\rho}{N_r} B^H B \right)$$

Où :

I_{N_r} la matrice d'identité de taille N_r , B^H est le conjugué de B

Dans notre travail on va utiliser deux techniques pour sélectionner le sous-ensemble k optimal :

- **Méthode d'optimisation convexe**
- **Réseau de neurone convolutionnel à Multi-Label (ML-CNN)**

6.3.1 CVX Méthode d'optimisation convexe



Figure 6.1 modèle de sélection d'antenne par CVX

Le problème de sélection d'antenne est formulé comme un problème d'optimisation convexe, qui peut être résolu efficacement par les méthodes numériques comme l'algorithme à point intérieur. Le problème d'optimisation est formulé ainsi :

$$\text{Maximize } E_r\{\log_2 \det(I + \frac{\rho}{N} H H')\}$$

$$\text{subject to } \Delta_i \in \{0,1\}$$

$$\sum_{i=1}^{Nt} \Delta_i = Ns.$$

Où « Δ_i » est une matrice diagonale avec des éléments, $i=1,2,\dots,Nt$ à la diagonale sont des variables binaires qui indiquent si l'antenne i est sélectionnée ou pas :

$$\Delta_i = \begin{cases} 1, & \text{selected} \\ 0, & \text{otherwise,} \end{cases}$$

Qui satisfait N_t

$$\sum_{i=1}^M \Delta_i = N_s$$

Et H est la matrice de canal globale qui relie les N_t antennes d'émission aux M_r usagers.

Dans ce travail, un toolbox CVX sous Matlab a été exploité pour résoudre ce problème.

6.3.2 ML-CNN

On considère la SA comme un problème de classification multi-labels, la matrice de canal H peut être considérée comme instance d'entrée pour chaque TTI, le vecteur AS δ est considéré comme le vecteur de labels tel que c'est montré dans la Figure 6.2. Des couches de convolution suivies par des couches de Pooling se situent entre l'entrée et la sortie du réseau.

Vu que le nombre d'antenne à la station de base est énorme, le nombre de combinaisons des antennes à activer sera très important, d'où l'impossibilité d'utiliser le CNN à single Label.

Pour cela, un Multi-Label CNN est nécessaire dans ce contexte dont chaque label est un vecteur de longueur N_t et chaque élément de ce vecteur désigne une antenne.

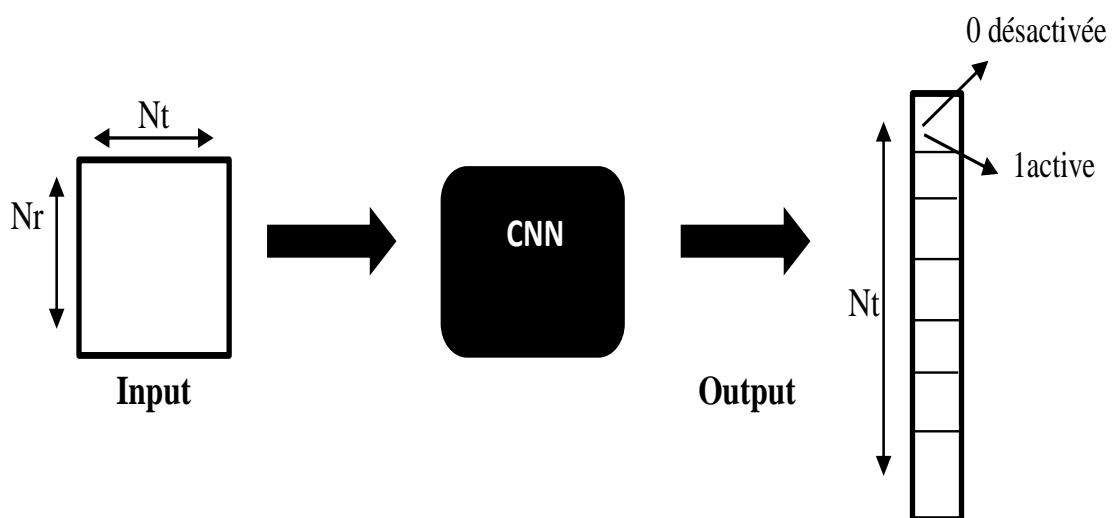


Figure 6.2 modèle sélection d'antenne par la méthode ML-CNN

6.4 Simulation et Interprétation des Résultats

6.4.1 Générations des Données

On crée dans une première phase une base de données de 10000 échantillons. Le canal de transmission radio H est généré par un processus aléatoire de moyenne zéro et variance 1.

A chaque matrice H de taille (Mt, Mr) est attribué un vecteur label des positions des antennes qui donne le maximum de capacité retrouvé par l'optimisation convexe.

- **1 ère scénario :**

On considère une station de base équipée de 32 antennes d'émission pour servir 4 usagers à antenne unique et on modifie à chaque fois la valeur le nombre d'antenne sélectionné, de sorte que les valeurs Ns prennent (16, 20, 24, 28, 30).

- **2ème scénario :**

On considère une station de base équipée de 64 antennes d'émission pour servir 4 usagers à antenne unique et on modifie à chaque fois la valeur le nombre d'antenne sélectionné, de sorte que les valeurs Ns prennent (16, 24, 48, 56).

- **3ème scénario :**

On considère une station de base équipée de 128 antennes d'émission pour servir 4 usagers à antenne unique et on modifie à chaque fois la valeur le nombre d'antenne sélectionné, de sorte que les valeurs Ns prennent (16, 32, 48,96).

6.4.2 Application de la méthode ML-CNN

Fractionnement des données

La base de données est divisée comme suit :

6000 échantillons pour l'entraînement.

2000 échantillons pour la validation.

2000 échantillons pour le test.

Créer le modèle de réseau de neurone convolutif CNN

Le modèle est construit de :

- Une couche d'entrée.
- Trois couches convolutives :
 - 1 ère couche convolutive 2_D avec 8 filtres de taille [3 3].
 - 2ème couche convolutive avec 16 filtres de taille [3 3].
 - 3ème couche convolutive avec 20 filtres de taille [3 3].
- Une couche "fullyconnected".
- Trois couches de normalisation des données "batchNormalizationLayer".

L'entraînement :

Consiste à corriger les paramètres en calculant l'erreur entre les données réelles (channels, labels), et les prédicats du modèle par la technique de rétro-propagation et l'algorithme de

descente de gradient pour déterminer les meilleurs paramètres w, b afin de diminuer la fonction de perte.

Définir les paramètres d'entraînement :

- Nombre d'époques = 5, désigne qu'on doit passer 5 fois par les données d'entraînement.
- miniBatch = 256, désigne la quantité de données prises à chaque fois.
- L'accélération d'apprentissage du modèle est 0.01.

On utilise l'optimisateur Adam pour faire l'entraînement.

On définit le paramètre de la classification multi-labels $\text{threshold} = 0.5$

Validation :

La validation du modèle se fait en introduisant des nouvelles données et en recalculant l'erreur. Afin de juger si le modèle est généralisé ou pas.

On dit que le modèle est généralisé si la fonction de perte (Loss) sur les données de validation décroît.

Teste :

Les données de Test sont des données différentes de celles de l'entraînement et de validation utilisés pour vérifier si le modèle a pu retrouver la combinaison d'antenne qui maximise la capacité du système.

L'évaluation de la méthode proposée :

La performance du modèle ML-CNN est évaluée par deux métriques : loss-function et labelling F-score.

- **F-score**

La fonction F-score est une mesure de l'exactitude (précision) du système, c'est le nombre de prédictions correctes sur tous les échantillons ;

Dans notre cas, les échantillons sont binaires en sortie, on suppose une valeur de seuil (threshold) de 0,5. Donner par :

$$score = \frac{1}{NtNs} equal(y_n, \hat{y}_n)$$

Avec $0 \leq score \leq 1$ est la plage de précision, *Equal* (\cdot, \cdot) signifie la fonction qui compare les valeurs égales des arguments d'entrée.

- **Loss :**

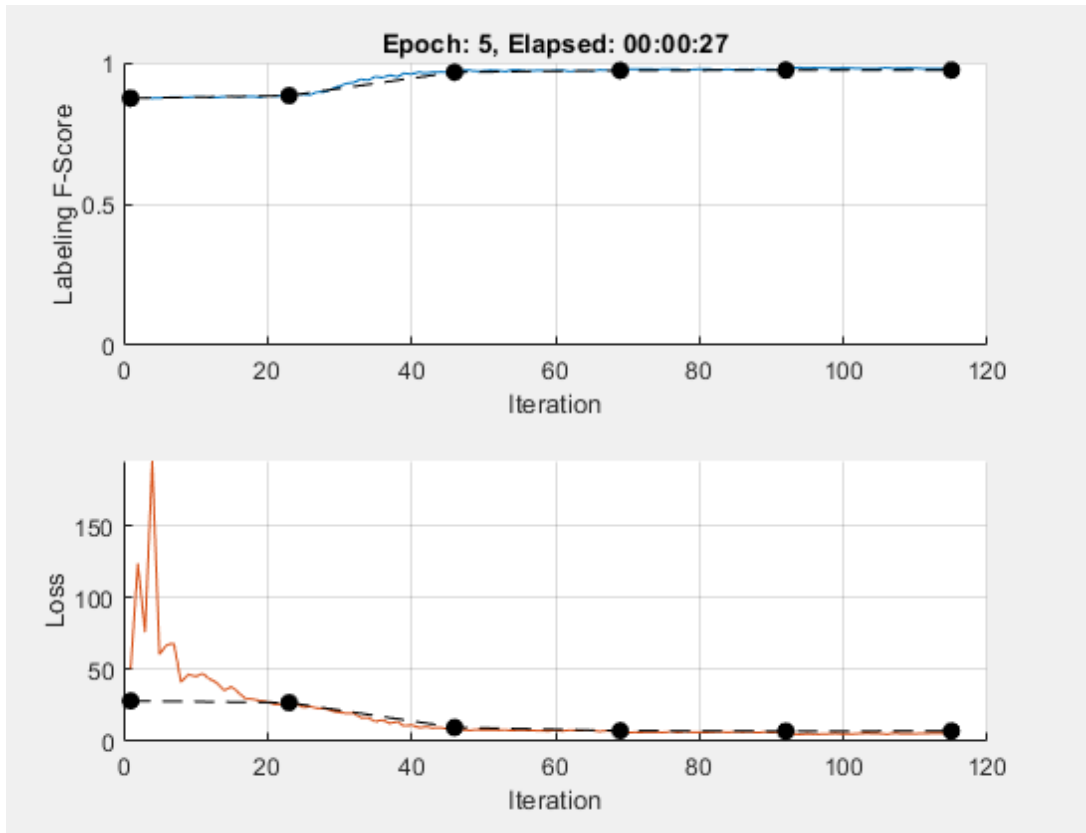
On a choisi la fonction de perte d'entropie croisée binaire (BCE)

$$\mathcal{L} = \frac{1}{N} \sum_{n=1}^N \hat{y}_n \cdot \log(y_n) + (1 - \hat{y}_n) \cdot \log(1 - \hat{y}_n)$$

Avec N est le nombre de batch, \hat{y}_n sortie prédit par le modèle, y sortie réelle.

A partir le calcul de ces deux derniers fonction on peut évaluer l'entraînement et la validation du modèle, on trace le graphe de F-score et loss en fonction de chaque itération pendant 5 périodes pour tous les scénarios.

6.4.3 l'Evaluation du modèle CNN



**Figure 6.3 la variation de F-score et Loss dans la partie d'entraînement
Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=10$.**

A travers la courbe du Loss, nous remarquons que la fonction Loss sur les données d'entraînement était maximale dans le début d'entraînement de 0 à 20, puis elle a commencé à diminuer et convergé vers le zéro.

Ce qui montre que la capacité du modèle est suffisante pour le problème.

D'autre part on remarque que la valeur la fonction de perte sur les données de validation est faible et aussi décroît au fil d'itérations.

La courbe de Labeling-F-score, tend vers 1 à l'itération 50. D'après les deux courbes, le modèle aura la capacité de retrouver les labels optimaux.

6.4.4 Comparaison entre la méthode convexe et la méthode ML-CNN

On fait une comparaison entre la capacité maximale obtenue par la méthode convexe et la capacité maximale obtenu par la méthode ML-CNN, On fixe le SNR à 10 et on trace

La capacité en fonction de N_s pour les trois scenarios ; $N_t=32$, $N_t=64$ et $N_t=128$. Tel que c'est montré dans les Figures 5.4, 5.5, et 5.6, on peut déduire que :

La capacité maximale s'améliore avec l'augmentation du nombre d'antennes sélectionnées N_s .

La capacité maximale s'améliore avec l'augmentation du nombre d'antennes d'émission N_t .

Le modèle ML-CNN a fourni des résultats identiques à celles fournis par l'algorithme d'optimisation convexe et ceci quel que soit la taille du Label.

Scénario 01 :

La variation de la capacité maximale en fonction de N_s pour $N_t=32$, SNR=10

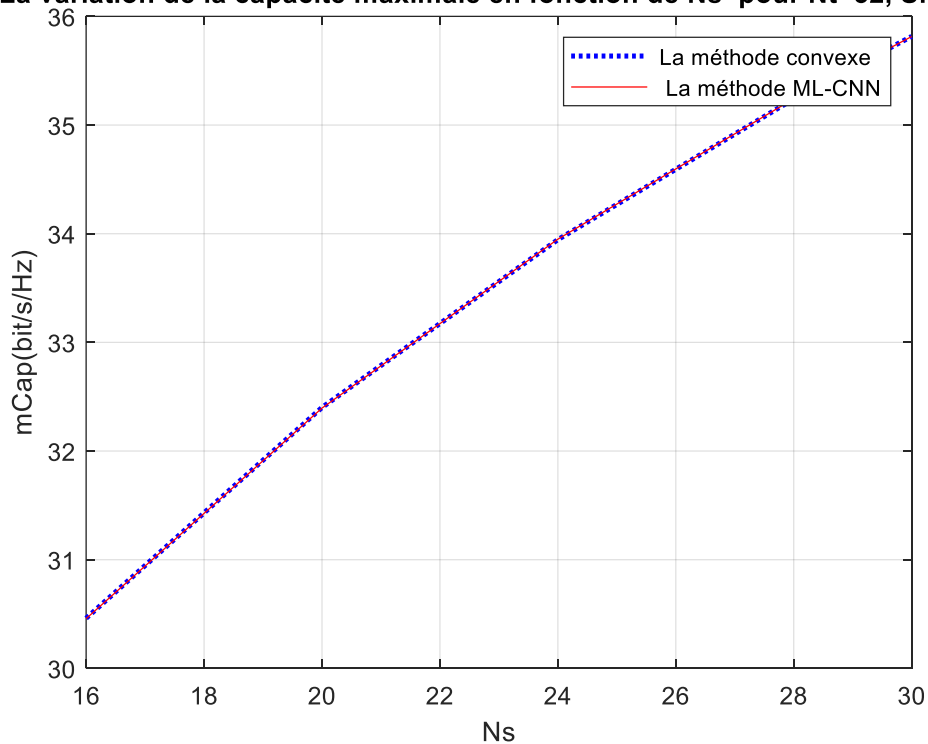


Figure 6.4

Scénario 02 :

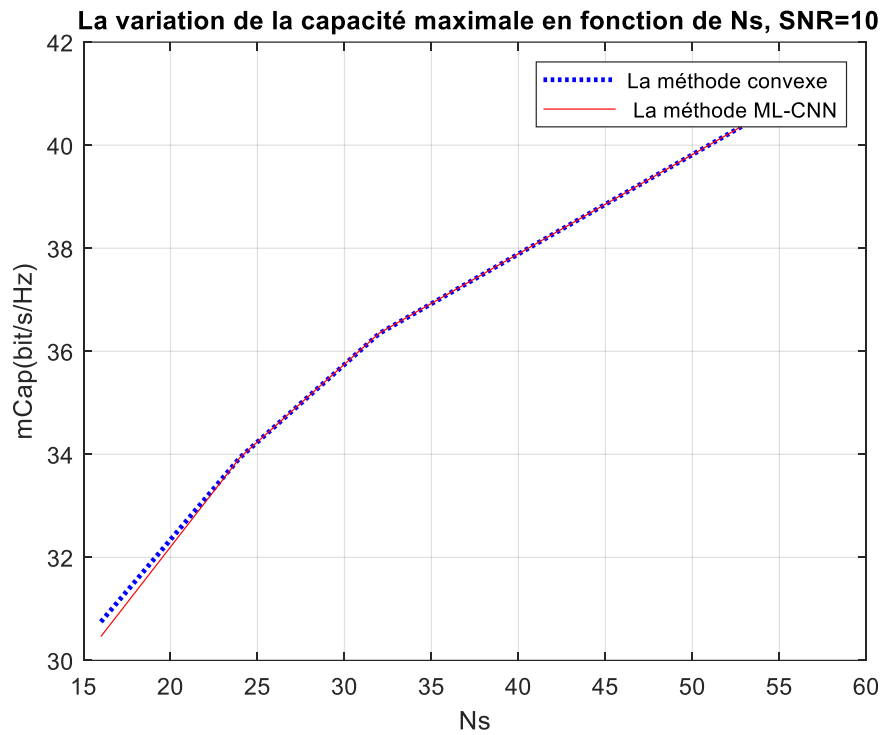


Figure 6.5

Scénario 03 :

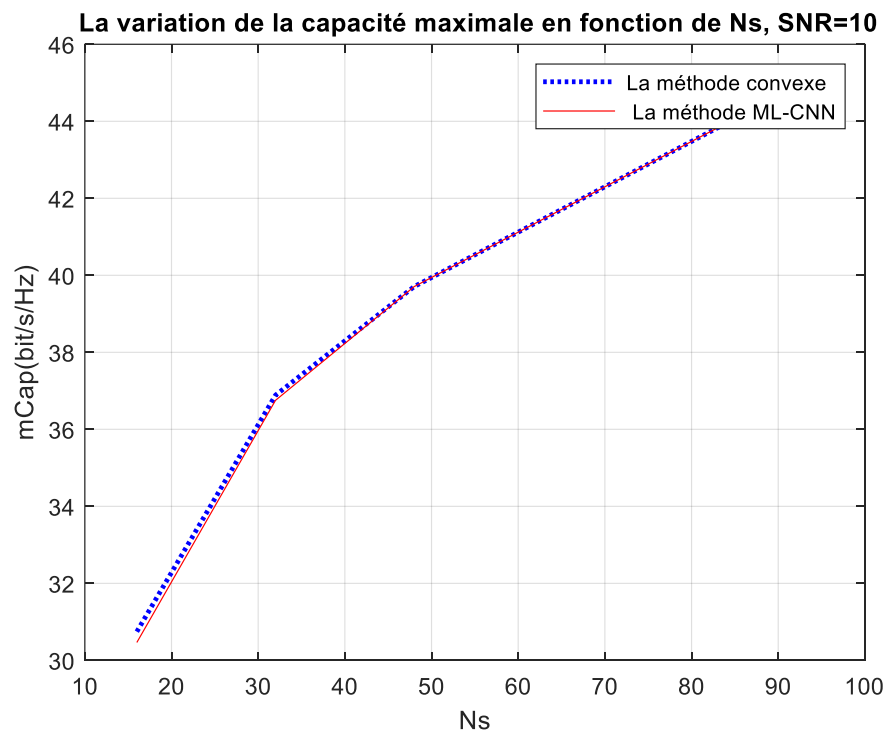


Figure 6.6

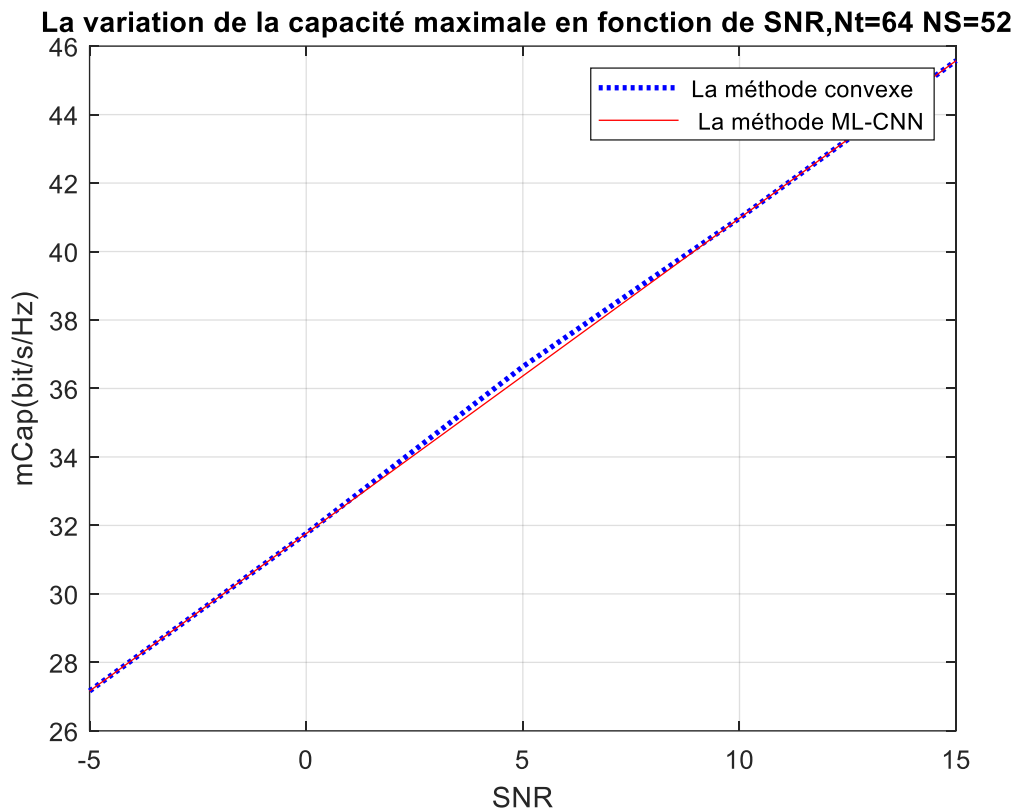


Figure 6.7

D'autre part, on compare les deux méthodes en terme de temps de calcul.

Scénario 01

Table 1 : le temps du calcule pour Nt=32, Ns=16

	SNR	-5	0	5	10	15
Nt=32 / N=16	Convexe-Temps [S]	2.4939792	2.902444	2.784864	2.784461	2.116257
	MLL-Temps [10^{-4} S]	0.31773	0.329375	0.347035	0.313845	0.320625

Table 2 : le temps du calcule pour Nt=32, Ns=20

	SNR	-5	0	5	10	15
Nt=32 / N=20	Convexe-Temps [S]	2.2289028	1.762485	2.5048474	3.520392	3.317904
	MLL-Temps [10^{-4} S]	0.374825	0.32669	0.306745	0.32536	0.39933

Table 3 : le temps du calcule pour Nt=32, Ns=24

	SNR	-5	0	5	10	15
Nt=32 / N=24	Convexe-Temps [S]	2.4143072	2.955260	2.7513697	2.188399	3.42023
	MLL-Temps [10 ⁻⁴ S]	0.032272	0.321765	0.324725	0.3627	0.32678

Table 4 : le temps du calcule pour Nt=32, Ns=28

	SNR	-5	0	5	10	15
Nt=32 / N=28	Convexe-Temps [S]	3.700819	3.4604699	3.4208311	3.845083	3.9321411
	MLL-Temps [10 ⁻⁴ S]	0.326045	0.3248	0.326555	0.33244	0.33241

Table 5 : le temps du calcule pour Nt=32, Ns=30

	SNR	-5	0	5	10	15
Nt=32 / N=30	Convexe-Temps [S]	2.985643	3.3761015	3.9995311	3.454156	4.1325597
	MLL-Temps [10 ⁻⁴ S]	0.35933	0.325425	0.327332	0.331445	0.324825

Scénario 02 :

Table 6 : le temps du calcule pour Nt=64, Ns=16

	SNR	-5	0	5	10	15
Nt=64 / N=16	Convexe-Temps [S]	1.737458	2.197722	1.898823	2.344723	2.501832
	MLL-Temps [10 ⁻⁴ S]	0.690895	0.608935	0.614555	0.698875	0.56915

Table 7 : le temps du calcule pour Nt=64, Ns=24

	SNR	-5	0	5	10	15
Nt=64 / N=24	Convexe-Temps [S]	1.778459	2.150391	2.211013	2.307052	2.450210
	MLL-Temps [10 ⁻⁴ S]	0.62554	0.56678	0.55917	0.607685	0.68335

Table 8 : le temps du calcule pour Nt=64, Ns=32

	SNR	-5	0	5	10	15
Nt=64 / N=32	Convexe-Temps [S]	2.1015983	2.2389793	2.446422	2.3945793	2.747374
	MLL-Temps [10^{-4} S]	0.552715	0.618485	0.559645	0.572955	0.698195

Table 9 : le temps du calcule pour Nt=64, Ns=56

	SNR	-5	0	5	10	15
Nt=64 / N=56	Convexe-Temps [S]	2.2554577	2.1569045	2.8978362	2.809373	3.0198494
	MLL-Temps [10^{-4} S]	0.565155	0.57139	0.544505	0.563115	0.56977

Scénario 03

Table 10 : le temps du calcule pour Nt=128, Ns=16

	SNR	-5	0	5	10	15
Nt=128/N=16	Convexe-Temps [S]	3.476804	4.5266004	3.218259	4.7058733	4.004556
	MLL-Temps [10^{-4} S]	0.922345	1.22315	0.940745	0.9359	0.96154

Table 11 : le temps du calcule pour Nt=128, Ns=32

	SNR	-5	0	5	10	15
Nt=128/N=32	Convexe-Temps [S]	3.700213	3.825824	4.09160	3.52789	4.188252
	MLL-Temps [10^{-4} S]	0.926	0.9452	0.91085	0.932569	1.00978

Table 12 : le temps du calcule pour Nt=128, Ns=48

	SNR	-5	0	5	10	15
Nt=128/N=48	Convexe-Temps [S]	3.187311	3.393193	4.153693	4.187734	4.963375
	MLL-Temps [10^{-4} S]	1.06305	0.968335	1.13167	0.97842	0.921765

Table 13 : le temps du calcule pour $N_t=128$, $N_s=96$

	SNR	-5	0	5	10	15
Nt=128/N=96	Convexe-Temps [S]	5.664314	4.401443	5.1875731	5.637768	6.468964
	MLL-Temps [10^{-4} S]	0.907965	0.938415	1.065695	0.937545	1.2397658

D'après les tableaux, on remarque que, pour toutes les valeurs du SNR, N_t et N_s , la méthode ML-CNN est très rapide par rapport à la méthode CVX.

6.4.5 Performance du Modèle ML-CNN sur une base de données de mesure obtenue dans un canal Indoor

Les résultats montrent que la méthode ML-CNN appliquée sur des canaux de transmission de simulation était efficace pour optimiser les performances d'un système MASSIVE MIMO. Par la suite, on teste ses performances vis-à-vis des canaux de mesure réels. Trois scénarios seront considérés suivant la forme du réseau d'antenne à la station de base, à savoir, réseau linéaire, rectangulaire et distribué.

La base sur des données de mesure a été téléchargée de Sibren De Bast [36]. Ce dernier a fait une expérience en équipant dans un bureau une BS, contenant 64 antennes et quatre utilisateurs, il fait estimer avec le banc d'essai KU Leuven Massive MIMO des échantillons d'informations sur l'état du canal (CSI) selon plusieurs positions d'utilisateurs.

Les positions des utilisateurs est posées sur une grille de surface 1,25 m sur 1,25 m, l'antenne de chaque utilisateur est déplacé selon un chemin prédéfinie à l'aide de tables CNC XY.

Le déplacement est fait long d'un quadrillage par pas de 5 mm, ce qui donne une taille de Dataset de 252 004 échantillons.

Le CSI est estimé pour 100 sous-porteurs régulièrement espacées en fréquence sur une bande passante de 25 MHz et une fréquence de 2.61GHz, représenté par une matrice complexe H de taille $[N_t \times K]$, k est le nombre de sous-porteuses. L'expérience est faite pour trois déploiements du réseau d'antennes :

- Un réseau linéaire uniforme (ULA) de 64 antennes sur une ligne a été déployé.
- Un réseau rectangulaire uniforme (URA) de 8 par 8 antennes a été déployé.

- Un réseau distribué les 64 antennes ont été réparties dans la salle par paires de huit.

Ce qui résulte une Dataset contient 252 004 échantillons d'information d'état CSI pour chaque topologie (déploiement) mesurée, Ce Dataset est disponible pour être utilisé pour visualiser des procédures et valider des algorithmes.

Déploiement Linéaire ULA :




Figure 6.8 la variation de F-score et Loss dans la partie d'entraînement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=15$.

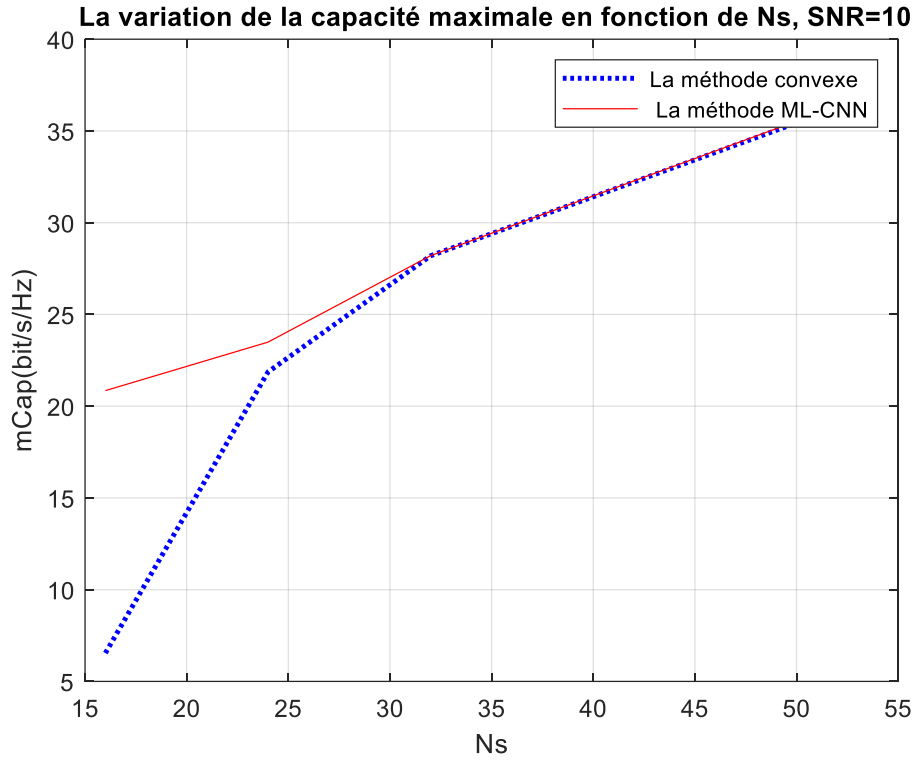


Figure 6.9

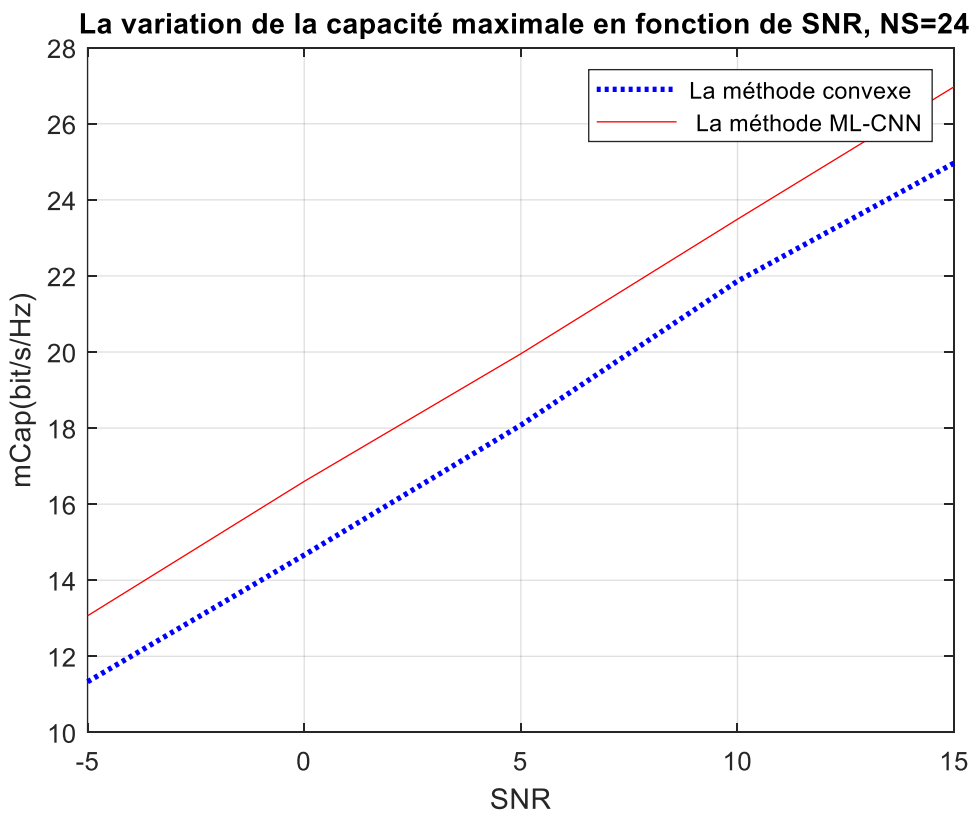


Figure 6.10

Table 14 : le temps du calcule pour Nt=64, Ns=16, ULA

	SNR	-5	0	5	10	15
Nt=64 / N=16	Convexe-Temps [S]	3.2249002	2.11090978	2.7288302	2.193874	2.901815
	MLL-Temps [m S]	0.49378	0.52271	0.49672	0.52009	0.54444

Table 15 : le temps du calcule pour Nt=64, Ns=24, ULA

	SNR	-5	0	5	10	15
Nt=64 / N=24	Convexe-Temps [S]	3.21694	2.5308372	2.2693044	2.2889402	3.51543
	MLL-Temps [m S]	0.49126	0.617355	0.490845	0.49635	0.558165

Table 16 : le temps du calcule pour Nt=64, Ns=32, ULA

	SNR	-5	0	5	10	15
Nt=64 / N=32	Convexe-Temps [S]	2.062699	2.0056211	2.003190	2.122812	3.2268414
	MLL-Temps [m S]	0.498455	0.54804	4.97025	0.49146	0.54452

Table 17 : le temps du calcule pour Nt=64, Ns=52, ULA

	SNR	-5	0	5	10	15
Nt=64 / N= 52	Convexe-Temps [S]	2.511312	2.960763	2.9693044	3.03162915	4.461895
	MLL-Temps [m S]	0.49443	0.534425	0.487475	0.58375	0.496565

Déploiement Rectangulaire URA :

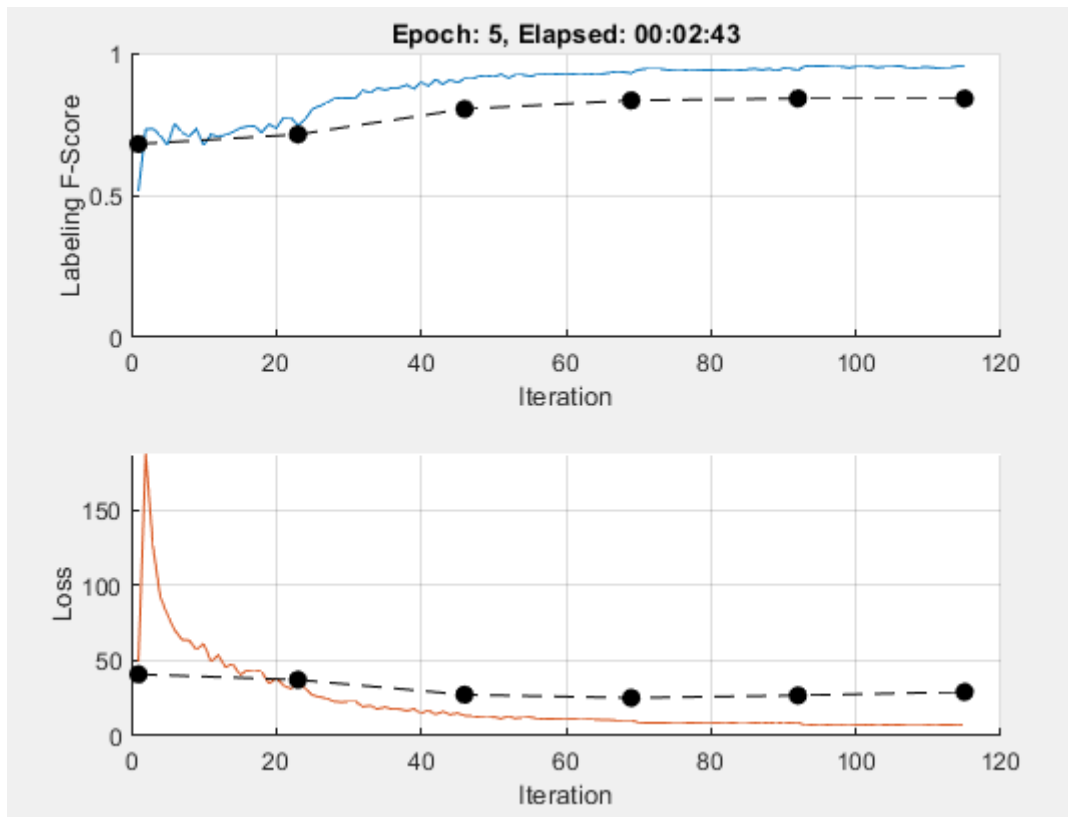


Figure 6.11 la variation de F-score et Loss dans la partie d'entrainement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=10$.




Figure 6.12




Figure 6.13

Table 18 : le temps du calcule pour Nt=64, Ns=16, URA

Nt=64 / N=16	SNR	-5	0	5	10	15
	Convexe-Temps [S]	3.273723	2.81767	3.3885712	3.46563	3.528453
	MLL-Temps [m S]	0.90666	2.53698	1.049695	0.71416	0.415733

Table 19 : le temps du calcule pour Nt=64, Ns=24, URA

Nt=64 / N=24	SNR	-5	0	5	10	15
	Convexe-Temps [S]	3.19915	2.86331	2.97847	3.46784	3.20302
	MLL-Temps [m S]	0.48194	0.59905	0.33515	0.33475	0.433325

Table 20 : le temps du calcule pour Nt=64, Ns=32, URA

Nt=64 / N=32	SNR	-5	0	5	10	15
	Convexe-Temps [S]	2.69213	3.22048	2.85715	3.40587	3.5581
	MLL-Temps [m S]	0.46073	0.48953	0.65177	0.52041	0.505204

Table 21 : le temps du calcule pour Nt=64, Ns=56, URA

Nt=64 / N=56	SNR	-5	0	5	10	15
	Convexe-Temps [S]	3.1281	3.41685	3.31810	3.00274	3.17618
	MLL-Temps [m S]	0.5063	0.71495	0.465833	0.701915	0.495616

Déploiement Distribué :

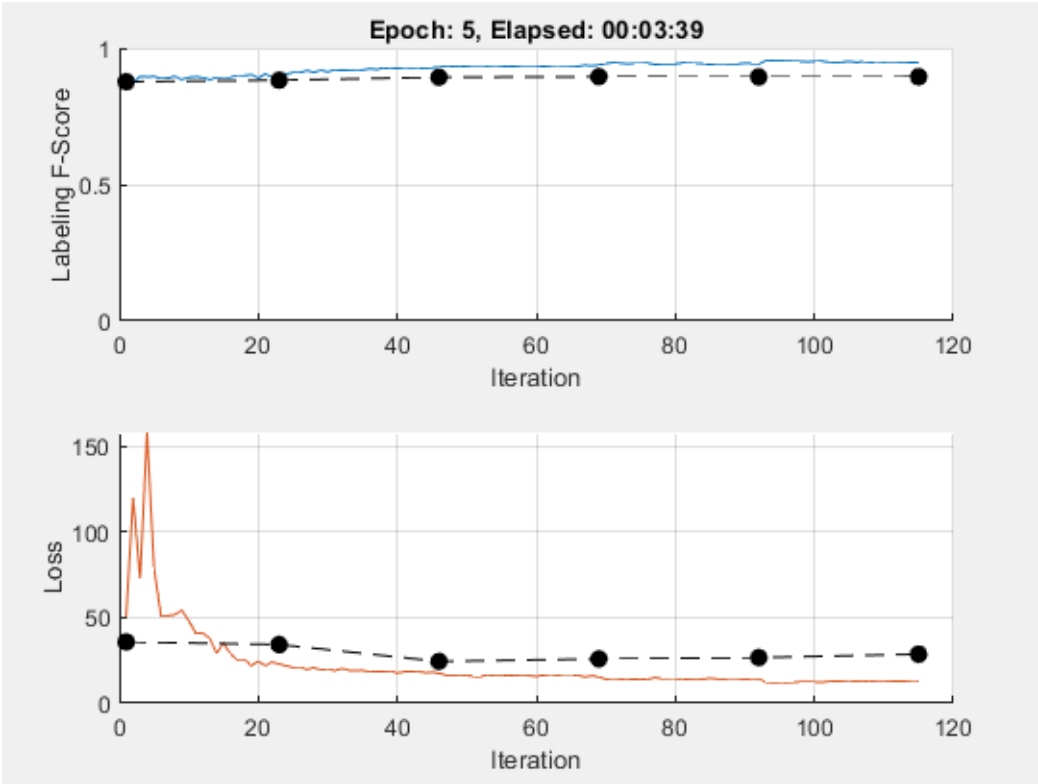


Figure 6.14 la variation de F-score et Loss dans la partie d'entrainement Et validation en fonction du nombre d'itérations pour : $N_t=64$, $N=56$, $SNR=10$.




Figure 6.15

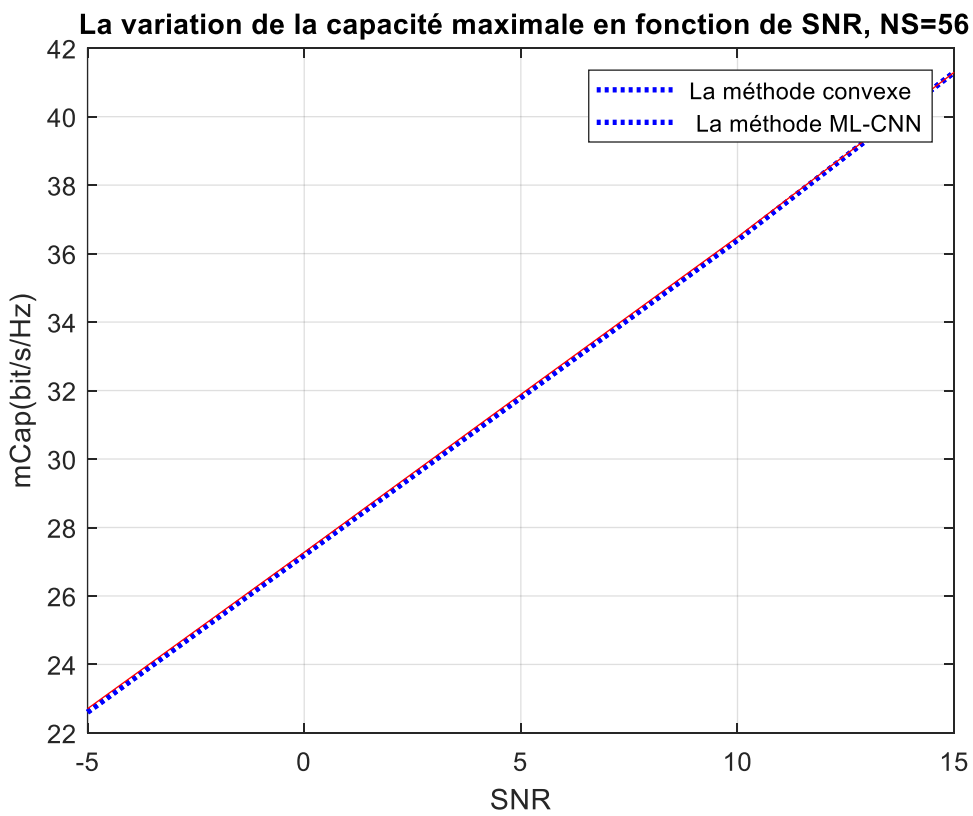


Figure 6.16

Table 22 : le temps du calcule pour Nt=64, Ns=16, D

Nt=64 / N=16	SNR	-5	0	5	10	15
	Convexe-Temps [S]	3.01884	2.53032	3.12506	3.14825	3.2591
	MLL-Temps [m S]	0.480135	0.74655	0.80672	0.864427	0.865113

Table 23 : le temps du calcule pour Nt=64, Ns=24, D

Nt=64 / N=24	SNR	-5	0	5	10	15
	Convexe-Temps [S]	2.94093	2.68767	2.71527	3.21557	2.95368
	MLL-Temps [m S]	0.474025	0.496976	0.49599	0.6119	0.504915

Table 24 : le temps du calcule pour Nt=64, Ns=32, D

Nt=64 / N=32	SNR	-5	0	5	10	15
	Convexe-Temps [S]	2.7357	3.26664	2.87986	3.447108	3.569873
	MLL-Temps [m S]	0.95854	0.656583	1.2096	0.737359	1.36674

Table 25 : le temps du calcule pour Nt=64, Ns=56, D

Nt=64 / N=56	SNR	-5	0	5	10	15
	Convexe-Temps [S]	3.93976	4.37809	4.022551	4.220091	4.47809
	MLL-Temps [m S]	1.58688	0.679475	0.93549	1.046907	0.770955

On remarque que la courbe de la fonction de perte Loss, pour les trois différents déploiements, sur les données d'entraînement décroît au fil d'itérations, également sur les données de validation on remarque que la valeur de la fonction est faible et décroît au fil d'itérations.

Ce qui montre que notre modèle a pu déterminer les paramètres de système correctes, donc la capacité du modèle est suffisante pour étiqueté le sous-ensemble optimal.

De la courbe de F-score, on remarque la croissance de la valeur de précision du système au fil des époques et les itérations Ceci confirme l'efficacité de la méthode ML-CNN proposée sur des données réelles.

6.5 Conclusion

Dans ce chapitre, on a proposé un algorithme ML-CNN dans le contexte de sélection d'antenne dans un système MIMO Massif. On l'a testé sur une base de données de simulation qu'on a générée nous-même. Puis on l'a testé sur une base de données de mesure dans un scénario Indoor avec trois configurations différentes du réseau d'antenne. Les performances du ML-CNN ont été comparées avec celles obtenues par l'algorithme d'optimisation convexe (considéré optimal) en terme de capacité de canal et temps de calcul. Des performances identiques ont été observés en terme de capacité, par contre, un temps de calcul considérablement réduit a été obtenu par le ML-CNN.

Conclusion générale

Dans ce travail qui consiste à appliquer la méthode de selection d'antenne basé sur un réseau de neurone convolutif sur des données du canal simulés et réelles, nous concluons que la méthode ML-CNN, est un moyen efficace pour trouver le sous-ensemble d'antenne sélectionnée optimal dans un temps record, ce que en fait que cette méthode est la meilleur pour améliorer les performances d'un système MASSIVE MIMO par rapport à la méthode CVX en terme d'amélioration de capacité et temps réduit.

Référence

- [1] Roopali Sood and Atul Garg. Digital Society from 1G to 5G. International Journal of Application or Innovation in Engineering & Management (IJAIEM), Févr.2014.
- [2] S. E. Hajri. L'amélioration des performances des systèmes sans fil 5G par groupements adaptatifs des utilisateurs. Université Paris-Saclay, 2018.
- [3] J. Andrews, S. Buzzi, W. Choi, S. Hanly, A. Lozano, A. Soong, and J. Zhang. "What will 5G be?. IEEE Journal on selected areas in communications, 2014.
- [4] .Etude de la capacité du canal pour un système MIMO massif. Laboratoire de recherche en Télécommunication, Automatique, Signal Et Images (LR-TASI) Ecole Doctorale en Sciences et Techniques de l'Ingénierie et de l'Innovation(EDSTII), 2016.
- [5] Dehemchi Marwa and Bouhafer Asma. Etude et Analyse de Méthodes de Beamforming pour des Systèmes Multi-utilisateurs Pour la 5G. université de 8 Mai 1945 Guelma, 2019.
- [6] Björnson, Emil, Jakob Hoydis and Luca Sanguinetti. Massive MIMO networks: Spectral, energy, and hardware efficiency. Foundations and Trends in Signal Processing, 2017.
- [7] [Shao-Yu Lien](#), [Shin-Lin Shieh](#), [Yenming Huang](#), [Borching Su](#), [Yung-Lin Hsu](#) and [Hung-Yu Wei](#). 5G New Radio : Waveform, Frame Structure, Multiple Access, and Initial Acces. [IEEE Communications Magazine](#), jun.2017.
- [8] G. FOSCHINI. Layered space-time architecture for wireless communication in a fading environment when using multi-element antennas. Bell Labs Technical Journal, 1996.
- [9] H. Shin and J. H. Lee. Capacity of multiple-antenna fading channels: spatial fading correlation, double scattering, and keyhole. IEEE Transactions on Information Theory, vol. 49, pp. 2636- 2647, Oct 2003.
- [10] I. E. Telatar. Capacity of multi-antenna Gaussian channels. European Trans. Telecommun, Dec 1999.
- [11] Zerrouki el-Hadj. Application de la technologie MIMO dans les réseaux WI-FI. Thèse de Magister en Télécommunications, Université ABOU-BEKR BELKAÏD, Tlemcen2006.
- [12] Study Paper on: Multiple-Input Multiple-Output (MIMO) Technology. page 4.
- [13] G. C. Raleigh and J. M. Cioffi. Spatio-temporal coding for wireless communication. IEEE Transactions on Communications, 1998.
- [14] A. F. Molisch. MIMO systems with antenna selection - an overview - in Radio and Wireless Conference., 2003
- [15] J. W. Wallace and M. A. Jensen. MIMO capacity variation with SNR and multipath richness from full :wave indoor FDTD simulations. in IEEE Antennas and Propagation Society International Symposium , 2003.
- [16] Chiang Ho, Meixiang Zhang and Renzheng Gao. Key Technologies in Massive MIMO. Collège d'ingénierie de l'information Université de Yangzhou, Yangzhou 225127, Chine

- [17] GOURAYI Ahlem. Efficacité Energétique dans les Systèmes MIMO Massive. Université SAAD DAHLAB de BLIDA, 2016.
- [18] Fu, Hua. Spectral resource optimization for MU-MIMO systems with partial frequency bandwidth overlay. INSA de Rennes, 2015
- [19] BOUTALEB Abdelkader and SLIMANI Mohamed EL Amine. Etude et évaluation des performances d'un système hybrid Beamforming Massive MIMO pour les réseaux 5G. Université Saida Dr Tahar Moulay – Faculté de TECHNOLOGIE, sep 2021.
- [20] Cai J-x, Zhong R, Li Y. Antenna selection for multiple-input multiple-output systems based on deep convolutional neural networks. PLoS ONE 14(5): e0215672. <https://doi.org/10.1371/journal.pone.0215672>, 2019
- [21] Joung J. Machine learning-based antenna selection in wireless communications. IEEE Communications Letters, 20(11):2241–2244, 2016.
- [22] Broudiscou.A, Leardi.R and Phan-Tan-Luu.R. Genetic algorithm as a tool for selection of D-optimal design. Chemometrics and Intelligent Laboratory Systems, 35, 105–116, 1996.
- [23] Wong, Weng ,Kee, Zhou ,Julie. CVX based algorithms for constructing various optimal regression designs. The Canadian Journal of Statistics, 2019.
- [24] Grant. M. C and Boyd.S. P. The CVX Users Guide, Release 2.0 (beta). CVX Research, Inc, Stanford University, 2013.
- [25] Boyd.S and Vandenberghe. L Convex Optimization. Cambridge University Press. New York, 2004.
- [26] Padmanabhan.S, Stephen.R, Murthy.C and Coupechoux.M. Training-based antenna selection for PER minimization: a pomdp approach. IEEE Transactions on Communications, 63(9):3247–3260, 2015.
- [27] Zhou.M, Cui.H, Song.L and Jiao.B. Transmit-receive antenna pair selection in full duplex systems. IEEE Wireless Communication Letters, 3(1):34–37, 2014.
- [28] Bengio.Y. Learning deep architectures for AI. 1st ed. Boston: Now Publishers Inc, 2009.
- [29] Lee.W, Jo.O and Kim.M. Application of End-to-End deep learning in wireless communications systems.
- [30] Greff.K, Srivastava RK, Koutnik.J, Steunebrink.B and Schmidhuber.J. LSTM: a search space odyssey. IEEE Transactions on Neural Networks Learning Systems, 28(10):2222–2232. <https://doi.org/10.1109/TNNLS.2016.2582924> 2018, Preprint. Available from: arXiv:1808.02394v1, 2015
- [31] M. Minsky and S. Papert. Perceptrons. MIT Press, (cf. p. 2), 1969
- [32] Y. LeCun and al. Backpropagation Applied to Handwritten Zip Code Recognition. In : Neural Computation 1.4 p. 541-551 (cf. p. 7), déc 1989.

- [33] Y. Bengio. Practical Recommendations for Gradient-Based Training of Deep Architectures. In : Neural Networks : Tricks of the Trade : Second Edition. Sous la dir. de G. Montavon, G. B. Orr et K.-R. Müller. Berlin, Heidelberg : Springer Berlin Heidelberg, p. 437-478 (cf. p. 7, 28), 2012.
- [34] I. Goodfellow, Y. Bengio et A. Courville. Deep Learning. <http://www.deeplearningbook.org>. MIT Press , (cf. p. 6, 12, 19, 21, 28-30, 93, 110), 2016
- [35] A. Krizhevsky, I. Sutskever et G. E. Hinton. ImageNet Classification with Deep Convolutional Neural Networks. Advances in neural Processing Systems de traitement, 2012.
- [36] sbren de bast. MASSIVE MIMO CHANNEL STATE INFORMATION MEASUREMENTS. KULEUVEN, 2019