



BIBLIOTHÈQUE

CÉGEP DE L'ABITIBI-TÉMISCAMINGUE
UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

Mise en garde

La bibliothèque du Cégep de l'Abitibi-Témiscamingue et de l'Université du Québec en Abitibi-Témiscamingue (UQAT) a obtenu l'autorisation de l'auteur de ce document afin de diffuser, dans un but non lucratif, une copie de son œuvre dans [Depositum](#), site d'archives numériques, gratuit et accessible à tous. L'auteur conserve néanmoins ses droits de propriété intellectuelle, dont son droit d'auteur, sur cette œuvre.

Warning

The library of the Cégep de l'Abitibi-Témiscamingue and the Université du Québec en Abitibi-Témiscamingue (UQAT) obtained the permission of the author to use a copy of this document for nonprofit purposes in order to put it in the open archives [Depositum](#), which is free and accessible to all. The author retains ownership of the copyright on this document.



UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE
ÉCOLE DE GÉNIE

**LOCALISATION BASEE SUR L'INFORMATION DE L'ETAT
DES CANAUX (CSI) DANS UN ENVIRONNEMENT MINIER
SOUTERRAIN**

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE

DE LA MAÎTRISE EN INGÉNIERIE

PAR

ALI KHALAF

MAI 2024

REMERCIEMENTS

En ce point d'achèvement de mon itinéraire de recherche, je ressens le besoin impérieux d'exprimer ma profonde gratitude envers tous ceux, de près ou de loin, qui ont nourri ma conviction et m'ont accompagné jusqu'à la clôture de cette thèse. Une reconnaissance toute particulière est dédiée à mon directeur de recherche, le Professeur *Nahi Kandil*. Sa confiance initiale, ses conseils avisés et son engagement scientifique ont constitué les fondements de ma progression. Parallèlement, je suis redevable au Professeur *Nadir Hakem*, mon co-directeur, dont les orientations éclairées et les encouragements constants ont constitué des jalons essentiels dans mon cheminement académique. Je tiens à souligner ma gratitude pour son dévouement et le temps consacré à guider mes travaux de recherche. Mes sincères remerciements s'adressent également à l'ingénieur Mr. *Mohamed Ailas* pour son aide précieuse dans mon projet. Sa profonde expertise et son expérience ont grandement contribué à la réalisation de mes objectifs. J'adresse également mes plus chaleureux remerciements au Professeur *Chahé Nerguizian*, ainsi qu'à mes collègues *Rabih Noureddine*, *Nabih Allaw*, *Mohamad Madi*, *Bassam Zahereddine*, *Chérine Diab*, *Ahmad Mouchaimech*, *Jana Allouch*, et à toute ma famille. Leur présence bienveillante et la convivialité partagée au quotidien ont grandement contribué à créer un environnement de travail stimulant et harmonieux. Leur esprit d'équipe et leur soutien ont été un atout précieux dans cette aventure académique.

TABLE DES MATIÈRES

<i>LISTE DES FIGURES</i>	<i>viii</i>
ABSTRACT	1
RÉSUMÉ	1
<i>Introduction:</i>	<i>5</i>
I. Motivation et problème:	5
II. Solutions Proposées:	6
III. Technologies:	8
IV. Hypothèses:	9
V. Objective:	10
<i>Chapitre 1</i>	<i>12</i>
<i>État de l'art :</i>	<i>12</i>
1.1. Un Système de Génération de Clés Sans Fil Piloté par ESP32 à Faible Coût Basé sur un Mécanisme de Réponse :	12
1.1.1. Aperçu :	12
1.1.2. Description du modèle et résultats :	13
1.2. Détection spatiale planifiée contre la détection WiFi adverse: ..	13
1.2.1. Aperçu :	13
1.2.2. Description du modèle et résultats :	14
1.3. Wi-CaL : Détection et localisation de foules sans dispositif via le WiFi et l'apprentissage automatique :	16
1.3.1. Aperçu :	16
1.3.2. Description du modèle et résultats :	16

1.4. Amélioration de la localisation intérieure sans dispositifs basée sur l'information de l'état de canal (CSI) utilisant une approche de classification par apprentissage automatique :	19
1.4.1. Aperçu :	19
1.4.2. Description du modèle et résultats :	20
1.5. CiFi : Réseaux Neuronaux Convolutionnels Profonds pour la Localisation Intérieure avec Wi-Fi 5GHz :	22
1.5.1. Aperçu :	22
1.5.2. Description du modèle et résultats :	22
Chapitre 2	25
<i>Matériels et logiciels :</i>	25
2.1. Aperçus :	25
2.2. Matériels :	25
2.2.1. Carte WiFi NIC5300	26
2.2.2. Esp32	28
2.3. Logiciels :	29
Chapitre 3	31
<i>État de canal sans fils :</i>	31
3.1. Introduction :	31
3.2. Installation et Configuration Matérielle :	34
3.3. Wi-Fi :	40
3.4. RSSI :	41
3.5. L'environnement des mesures :	42
3.6. Les Paramètre pertinents du canal :	44
3.7. Calibration de notre système :	49

Chapitre 4	53
Réseau de neurones artificiels :	53
4.1. Définition du réseau de neurone artificiels :	53
4.2. Application du réseau de neurone artificiel :	54
4.3. La Structure générale de RNA :	57
4.4. Fonctions d'activation pour RNA :	59
4.5. Types de RNA :	66
4.6. Différentes méthodes d'apprentissage :	69
4.7. Perceptron Multi-Couches :	70
4.8. Tensor Flow et Scikit-learn:	72
Chapitre 5	75
Méthodologie :	75
Chapitre 6	79
Test et résultat :	79
6.1. Introduction :	79
6.2. Environnement universitaire (Polytechnique de Montreal) :	80
6.2.1. Base de donnees	81
6.2.2. MLP en utilisant les deux algorithmes d'apprentissages automatique	82
6.2.3. L'entrainement de notre deux modèles	84
6.2.4. Comparaison des resultats pour les deux modeles	86
6.3. Environnement Industrielle souterraine :	88
6.3.1. Base de données	88
6.3.2. L'entrainement de notre deux modèles	90
6.3.3. MLP en utilisant les deux algorithmes d'apprentissages automatique	92
6.3.4. Comparaison des performances des deux modèles	101

<i>Chapitre 7</i>	<i>103</i>
<i>Conclusion :</i>	<i>103</i>
<i>Références</i>	<i>105</i>
<i>Annex a : exemple d'un paquet csi</i>	<i>107</i>

LISTE DES FIGURES

FIGURE 1: CONFIGURATION EXPÉRIMENTALE AVEC 5 ÉMETTEURS ET 1 RÉCEPTEUR POUR LA DÉTECTION D'ACTIVITÉS	15
FIGURE 2: MODULES ESP32 DANS UNE PIÈCE TEST	17
FIGURE 3: PERFORMANCE ET COMPARAISON ENTRE LES MÉTHODES D'APPRENTISSAGE.....	18
FIGURE 4: ARCHITECTURE DE SYSTÈME.....	20
FIGURE 5: PERFORMANCE DES DIFFÉRENTS SYSTÈMES	21
FIGURE 6: ARCHITECTURE DE SYSTÈME CIFI.....	23
FIGURE 7: FONCTION DE DISTRIBUTION CUMULATIVE DES ERREURS DE LOCALISATION POUR L'EXPÉRIENCE EN LABORATOIRE	24
FIGURE 8: CARTE NIC5300	27
FIGURE 9: CONCEPT DE DÉTECTION WI-FI SANS DISPOSITIF (DFWS).....	29
FIGURE 10: L'AMPLITUDE DE CFR DE 5 PAQUETS POUR 1 SEUL POINT DE MESURE.....	33
FIGURE 11: L'AMPLITUDE DE CIR DE 5 PAQUETS POUR 1 SEUL POINT DE MESURE.....	33
FIGURE 12: NOTRE VERSION DE ESP AVEC LES ANTENNES EXTERNES	37
FIGURE 13: PHOTOGRAPHIE DES CONFIGURATIONS POUR LES ESP32	38
FIGURE 14: L'ENVOI DES PAQUETS DE AP	39
FIGURE 15: VISUALISATION DES CSI D'ESP PASSIVE	39
FIGURE 16: POSITION DE ESP PASSIVE ET POSITION DE AP ET STA (MINE).....	43
FIGURE 17: PHOTOGRAPHIE DE GALERIE DE MINE.....	44
FIGURE 18 : DÉLAI RMS ET DÉLAI MOYEN EN FONCTION DE DISTANCE POUR LIGNE DE VISÉE	47
FIGURE 19 : DÉLAI RMS ET DÉLAI MOYEN EN FONCTION DE DISTANCE POUR NON-LIGNE DE VISÉE	47
FIGURE 20 : RSSI ET RÉGRESSION LINÉAIRE EN FONCTION DE DISTANCE EN ÉCHELLE LOGARITHMIQUE	50
FIGURE 21 : SOMME DES AMPLITUDES CARRÉS ET LA RÉGRESSION LINÉAIRE EN FONCTION DE DISTANCE EN ÉCHELLE LOGARITHMIQUE	51
FIGURE 22: APPLICATION DE RNA	55
FIGURE 23: PRESENTATION MATHEMATICAL DU RNA.....	59
FIGURE 24 : FONCTION SIGMOÏDE	60
FIGURE 25 : FONCTION DE TANGENTE HYPERBOLIQUE	61
FIGURE 26 : FONCTION RELU	63
FIGURE 27 : FONCTION LEAKY RELU.....	64

FIGURE 28 : FONCTION SOFTMAX.....	65
FIGURE 29 : RNA À COUCHES MULTIPLES	67
FIGURE 30 : EXEMPLE DE RÉSEAUX DU NEURONE CONVOLUTIFS	68
FIGURE 31 : RÉSEAUX DE NEURONES RÉCURRENTS (RNN)	69
FIGURE 32 : STRUCTURE ABSTRAITE D'UN RÉSEAU MLP	71
FIGURE 33 : DIAGRAMME DE MÉTHODOLOGIE	76
FIGURE 34 : L'ENTRÉE ET LES SORTIES DE NOTRE RÉSEAU DE NEURONE	79
FIGURE 35 : ENVIRONNEMENT UNIVERSITAIRE (POLYTECHNIQUE DE MONTRÉAL)	80
FIGURE 36 : POSITIONS DE ESP PASSIVE ET POSITION DE AP ET STA	81
FIGURE 37 : LA PERTE D'APPRENTISSAGE ET DE VALIDATION POUR TF (POLY)	84
FIGURE 38 :LA PERTE D'APPRENTISSAGE ET DE VALIDATION SCIKIT-LEARN (POLY)	84
FIGURE 39 : CDF DES DEUX MODÈLES.....	86
FIGURE 40 : LA PERTE D'APPRENTISSAGE ET DE VALIDATION POUR TF.....	90
FIGURE 41 : LA PERTE D'APPRENTISSAGE ET DE VALIDATION SCIKIT-LEARN	91
FIGURE 42 : ERREURS DE LOCALISATION EN TERMES DE X, Y ET D EN UTILISANT TF.....	93
FIGURE 43 : COMPARAISON DES POSITIONS ESTIMÉES ET EXACTES EN X ET EN Y EN UTILISANT TF.....	94
FIGURE 44 : VISUALISATION DES POSITIONS ESTIMÉES ET EXACTES DANS LE PLAN XY EN UTILISANT TF	95
FIGURE 45 : FONCTIONS DE RÉPARTITION CUMULÉE DES ERREURS DE LOCALISATION EN UTILISANT TF	96
FIGURE 46 : ERREURS DE LOCALISATION EN TERMES DE X, Y ET D EN UTILISANT SC-L	97
FIGURE 47 : COMPARAISON DES POSITIONS ESTIMÉES ET EXACTES EN X ET EN Y EN UTILISANT SC-L ..	98
FIGURE 48 : VISUALISATION DES POSITIONS ESTIMÉES ET EXACTES DANS LE PLAN XY EN UTILISANT SC-L	99
FIGURE 49 : FONCTIONS DE RÉPARTITION CUMULÉE DES ERREURS DE LOCALISATION EN UTILISANT SC-L	100

ABSTRACT

In the context of our comprehensive research within the Canadian mining industries, our goal has been to enhance underground communication networks through innovative wireless solutions, crucial for improving productivity and ensuring effective coordination among teams. Our study focused on the accuracy of mobile device localization in subterranean environments, leveraging a detailed analysis of Channel State Information (CSI).

Our methodology unfolded in two distinct phases of CSI data collection. Initially, it involved the use of NIC5300 cards, followed by the adoption of ESP32 modules for more in-depth collection. This strategy enabled us to thoroughly cover an indoor space.

A critical aspect of our research was the meticulous adjustment of channel parameters to boost the performance of artificial neural networks (ANN) in precisely locating mobile devices underground. We rigorously evaluated various configurations of multilayer perceptrons (MLP) and employed advanced tools such as TensorFlow and Scikit-learn to ascertain which configuration yielded the highest localization accuracy.

RÉSUMÉ

Dans le cadre de notre recherche approfondie au sein des industries minières canadiennes, notre objectif est de renforcer les réseaux de communication souterrains à l'aide de solutions sans fil innovantes, essentielles pour améliorer la productivité et garantir une coordination efficace entre les équipes. Notre étude s'est concentrée sur la précision de localisation des dispositifs mobiles dans les environnements souterrains, grâce à une analyse détaillée de l'état de canal sans fils (CSI).

Notre méthodologie s'est développée en deux phases distinctes de collecte de données CSI. La première a impliqué l'utilisation de cartes NIC5300, puis l'adoption de modules ESP32 pour une collecte plus approfondie. Cette approche a permis de couvrir exhaustivement un espace intérieur.

Un volet crucial de notre recherche réside dans l'ajustement minutieux des paramètres de canal, visant à optimiser la performance des réseaux de neurones artificiels (ANN) pour la localisation précise des dispositifs mobiles en milieu souterrain.

Nous avons évalué rigoureusement différentes configurations de perceptrons multicouches (MLP) et avons utilisé des outils avancés tels que Tensor Flow et Scikit-learn pour déterminer la configuration offrant la meilleure précision de localisation.

LISTE DES VARIABLES

PIB	Produit Intérieur Brut
CSI	L'état de Canal Sans Fils
IoT	Internet des objets
IA	Intelligence Artificielle
MAC	Contrôle d'Accès au Support
Non-RF	Radioélectriques
RF	Radiofréquences
IR	Rayonnement infrarouge
TDOA	La différence de temps d'arrivée
AoA	Angle d'Arrivée
RFID	Identification par radiofréquence
UWB	La bande ultra large
RSSI	Indicateur de Force du Signal Reçu
BLE	Bluetooth
SVM	Machine à Vecteurs de Support
KNN	K-Nearest Neighbors
ACP	Analyse des composantes principales
IPS	Systèmes de positionnement intérieur
GPS	Système de Positionnement Global
CFR	Réponses fréquentielles du canal
WiFi	Wireless Fidelity
DNN	Réseaux neuronaux denses
SGD	Descente de Gradient Stochastique
MAE	Erreur absolue médiane
MIMO	Entrées Multiples Sorties Multiples
OFDM	Multiplexage par répartition orthogonale de la fréquence
DCNN	Réseaux neuronaux convolutionnels profonds
CIR	Réponse impulsionnel de canal
AP	Point d'accès
STA	Station
LLTF	Long Training Field (Champ de formation longue)
BPSK	Modulation par déphasage binaire
LOS	Ligne de visée
NLOS	Non-ligne de visée
RNA	Réseaux de neurone artificiel
Tanh	Fonction tangente hyperbolique
ReLU	Fonction d'unité linéaire rectifiée
CNN	Réseaux de neurones convolutifs
RNN	Réseaux de neurones récurrents
MLP	Perceptron multicouche

CDF	Fonction de Répartition Cumulative
MSE	Erreur quadratique moyenne

INTRODUCTION:

I. *Motivation et problème:*

L'industrie minière canadienne, solide pilier de l'économie nationale, a poursuivi son expansion, contribuant de manière substantielle au Produit Intérieur Brut (PIB) du pays et assumant un rôle vital dans l'approvisionnement mondial en minéraux stratégiques. En 2021, ce secteur a contribué à hauteur de 125 milliards de dollars au PIB canadien, représentant 5% du total, tandis que l'ensemble des activités minières, de carrières, et d'extraction pétrolière et gazière a compté pour 7,9% du PIB global de 2 trillions de dollars. En outre, en août 2023, la production minière a enregistré une croissance de 0,95% par rapport à l'année précédente [1].

Devant cet essor et l'accroissement conséquent de son importance, il s'avère impératif d'élaborer des réseaux de télécommunication sans fil convenant aux environnements souterrains. Ces réseaux doivent être conçus pour surmonter les obstacles induits par des conditions extrêmes, telles que les températures élevées et la poussière, tout en s'adaptant aux sites miniers en perpétuelle mutation. Ils s'avèrent cruciaux non seulement pour optimiser la productivité, mais aussi pour garantir la sécurité des travailleurs. Ces systèmes résilients permettent la communication entre les mineurs et doivent supporter une gamme variée d'applications, allant de la surveillance des systèmes de sécurité à la gestion minière, le tout à travers une infrastructure économiquement viable.

Cependant, le principal défi dans le secteur minier réside dans l'assurance d'une localisation souterraine précise et fiable. Les méthodes conventionnelles de localisation échouent souvent sous terre, où la complexité du milieu perturbe les communications sans fil. Ce problème, d'une gravité essentielle pour l'efficacité opérationnelle et la sécurité des travailleurs, constitue le cœur de notre étude.

Dans cette perspective, notre étude sur l'exploitation de l'état de canal sans fils

pour la localisation en milieu souterrain se révèle indispensable. Notre analyse propose une évaluation minutieuse des caractéristiques du signal au sein d'un canal de communication sans fil, autorisant une localisation précise des appareils mobiles dans des environnements complexes et changeants tels que les mines. En tirant profit des données fournies par l'état de canal sans fils, il est envisageable de concevoir des réseaux de communication sans fil non seulement précis en matière de localisation, mais aussi adaptés aux défis spécifiques des milieux miniers, tels que les interférences ou les variations de signal engendrées par les conditions souterraines. Cette approche technique avancée améliore la fiabilité et l'efficacité des systèmes de communication dans l'industrie minière.

II. *Solutions Proposées:*

L'intégration du l'état de canal sans fils dans les réseaux de communication souterrains se profile comme une avancée de taille pour une localisation à la fois précise et fiable dans les milieux miniers. En scrutant avec finesse les subtilités des signaux parcourant le canal, cette intégration offre une réponse robuste et adaptable aux défis spécifiques affrontés dans les sites des mines souterraines. Sa capacité à discerner les variations subtiles de l'état du canal permet de surmonter les interférences et les obstacles physiques couramment présents sous terre, tels que les changements de densité des roches, les infrastructures métalliques, ou les conditions extrêmes de température et d'humidité. En tirant parti de ces données, la localisation et le suivi minutieux des dispositifs mobiles au sein de la mine deviennent aisés, garantissant ainsi une communication fluide et sécurisée entre les travailleurs.

Cette précision ne se borne pas à renforcer la sécurité, en autorisant des interventions promptes en cas d'urgence, mais elle participe également à l'optimisation des opérations minières en procurant des données fiables pour la

gestion des ressources et l'organisation des activités. Parallèlement, l'adoption du CSI dans les systèmes de communication miniers modernes ouvre la voie à l'intégration de technologies de pointe comme l'internet des objets (IoT) et l'intelligence artificielle (IA), offrant ainsi une analyse en temps réel et une prise de décision basée sur des données précises et à jour. Malgré les défis de son déploiement, tels que la complexité de son intégration dans les environnements souterrains et le besoin d'une maintenance régulière pour en assurer la précision, le potentiel du CSI pour l'industrie minière est considérable, ouvrant des horizons vers des systèmes de communication et de localisation encore plus élaborés et adaptés aux exigences spécifiques de ce secteur.

L'exploitation de la caractéristique de la couche physique de l'état de canal sans fils, dans les systèmes de localisation intérieure, se présente comme une solution prometteuse pour renforcer la précision et la fiabilité du positionnement intérieur. Contrairement aux méthodes traditionnelles basées sur les signaux géométriques et les empreintes digitales, souvent compromises par les phénomènes de fading et les réflexions de signal dans des environnements intérieurs complexes, notre approche se distingue par sa capacité à surmonter ces limitations. Elle offre une résolution supérieure à celle obtenue par la mesure de la couche Contrôle d'Accès au Support (MAC), limitée à une mesure par transmission et susceptible d'être perturbée par la présence de personnes.

L'état de canal sans fils fournit des informations détaillées sur la réponse du canal de communication entre les antennes émettrices et réceptrices, facilitant ainsi la création d'une base de données des caractéristiques d'empreintes digitales les plus représentatives pour la localisation intérieure. Cette base peut être mise à jour en temps réel, permettant une adaptation précise aux changements environnementaux internes.

III. *Technologies:*

Les technologies employées dans la localisation intérieure se répartissent en deux catégories principales : les technologies non basées sur les fréquences radioélectriques (non-RF) et celles basées sur les radiofréquences (RF). Parmi les méthodes non-RF, plusieurs technologies émergent: le Son, le Rayonnement infrarouge (IR), les capteurs inertiels, les systèmes géomagnétiques, les ultrasons, et la lumière visible. En ce qui concerne la localisation par le son, deux approches principales se dégagent : la différence de temps d'arrivée (TDOA) et l'angle d'arrivée (AoA). La TDOA repose sur l'analyse du temps de propagation du son depuis plusieurs émetteurs jusqu'à un récepteur, permettant une triangulation précise de la position de la cible, comme évoqué dans les études [2, 3, 4]. L'AoA, quant à elle, se concentre sur la détermination de l'angle sous lequel le son parvient à chaque nœud récepteur, offrant une autre dimension de localisation précise.

En ce qui concerne l'IR, cette technique requiert une balise IR fixée à la cible, qui émet des signaux vers un réseau de récepteurs. Bien que cette méthode soit précise, elle est limitée par la nécessité d'une ligne de visée directe et la courte portée des signaux IR, nécessitant ainsi un grand nombre de récepteurs. Malgré ces contraintes, l'IR a été utilisé dans des études pionnières comme celui mentionné dans la référence [5], où des badges IR sont utilisés pour localiser le personnel au sein d'une organisation, et reste pertinent dans certains contextes de recherche, comme en témoignent les références [6, 7].

Concernant des technologies RF, plusieurs systèmes jouissent d'une popularité, notamment le Bluetooth, l'identification par radiofréquence (RFID), la bande ultra large (UWB) et le Wi-Fi. Par exemple, la recherche présentée dans la référence [8] utilise une approche de crowdsourcing avec l'algorithme SVM, exploitant les

capteurs de smartphones pour créer des repères BLE dans la phase de formation. Une autre étude, mentionnée dans la référence [9], s'appuie sur le RSSI pour la localisation intérieure, en y ajoutant des filtres auto-adaptatifs pour améliorer la stabilité du signal BLE. De plus, l'étude [10] présente une approche de prise d'empreintes digitales basée sur l'RSSI, où les données sont collectées auprès de six points d'accès à l'étape hors ligne, puis traitées par l'analyse des composantes principales (ACP) pour une classification efficace à l'aide de différents algorithmes, tels que KNN, arbre de décision, forêt aléatoire et SVM. Enfin, le positionnement intérieur repose largement sur deux techniques : la géométrie et la cartographie. La géométrie utilise des caractéristiques du signal telles que le RSSI, ToA, TDoA, AoA, AoD, ou l'information sur l'état du canal pour localiser la cible en utilisant des méthodes de trilatération et de triangulation. Les techniques de cartographie, également connues sous le nom d'empreinte digitale, exploitent les caractéristiques du signal recueillies lors d'une phase hors ligne pour construire une carte radio composée des caractéristiques du signal et des coordonnées de chaque point de mesure, fournissant ainsi une représentation détaillée et précise de l'environnement intérieur.

IV. *Hypothèses:*

Dans le cadre de cette recherche, nous avançons l'hypothèse que l'association des données de l'état de canal sans fils et de l'indicateur de puissance du signal reçu (RSSI) pourrait considérablement améliorer la précision et la fiabilité des systèmes de positionnement intérieur (IPS) pour la localisation dans des environnements bâtis. Cette combinaison vise à pallier les insuffisances des méthodes traditionnelles de localisation, basées sur la géométrie des signaux et les techniques d'empreintes digitales, souvent limitées par des phénomènes tels que la décoloration du signal et les réflexions dans des milieux intérieurs complexes. L'intégration du CSI, qui

fournit une analyse détaillée de l'état du canal de communication, avec les mesures du RSSI, pourrait offrir une perspective enrichie et plus dynamique pour la détection précise de la localisation en milieu intérieur.

Notre hypothèse repose sur le potentiel de l'état de canal sans fils à capter les nuances subtiles des propriétés du canal, combiné à l'efficacité du RSSI en tant qu'indicateur de la force et de la direction du signal. Cette synergie entre le CSI et le RSSI devrait permettre la création d'une base de données de localisation enrichie, capable de s'adapter de manière optimale aux variations constantes de l'environnement intérieur. En exploitant ces informations de canal dans leur forme la plus pure, nous prévoyons de mettre au point un système de localisation intérieure plus précis et plus fiable, capable de fonctionner efficacement même dans les environnements les plus exigeants. Cette étude vise à démontrer que l'utilisation conjointe du CSI et du RSSI surpasse les méthodes conventionnelles en termes de précision et de fiabilité, ouvrant ainsi la voie à des avancées significatives dans les technologies de localisation intérieure. En validant cette hypothèse, nous espérons non seulement améliorer les systèmes de positionnement intérieur existants, mais également explorer de nouvelles possibilités d'application, rendant la localisation en milieu bâti plus adaptable, réactive et personnalisée aux besoins spécifiques des utilisateurs et aux particularités architecturales de chaque bâtiment. Les résultats attendus pourraient transformer profondément les méthodes actuelles de localisation en milieu bâti, en exploitant de manière optimale la richesse des informations disponibles dans les signaux de communication sans fil.

V. *Objective:*

L'objectif principal de cette recherche est de développer un système de positionnement intérieur avancé, spécifiquement conçu pour la localisation en milieu minier souterrain, en intégrant les informations de l'état de canal sans fils et

de l'indicateur de puissance du signal reçu (RSSI). Cette approche vise à surmonter les défis uniques associés à l'environnement souterrain des mines, où les méthodes traditionnelles de localisation peuvent être insuffisantes en raison de la complexité du milieu, comme les structures métalliques, les variations de terrain et les conditions de signal variables.

D'abord, notre recherche consiste à édifier une base de données de localisation précise et fiable, tenant compte des caractéristiques propres aux environnements miniers souterrains. Cette base de données combinera les données CSI et RSSI pour fournir une représentation détaillée de l'espace souterrain, permettant une localisation et un suivi précis des équipements et du personnel minier.

Ensuite, notre recherche tente de mettre à l'épreuve et de valider la performance de ce système dans diverses conditions minières souterraines. Cela implique des expériences dans différentes configurations de mines, avec différents niveaux d'interférence de signal et de conditions physiques, garantissant la robustesse et la fiabilité du système dans un éventail varié de situations minières. En outre, cette recherche explorera la manière dont cette technologie de localisation peut renforcer la sécurité et l'efficacité opérationnelle dans les mines souterraines, un aspect particulièrement vital dans un contexte où la sécurité des travailleurs est primordiale et où une localisation précise peut exercer une influence majeure dans les opérations de secours en cas d'urgence et dans la gestion quotidienne des activités minières.

Enfin, notre recherche aspire à fournir une solution de localisation souterraine qui représente une avancée significative par rapport aux systèmes existants, en offrant une plus grande précision, fiabilité et adaptabilité accrues aux conditions spécifiques des environnements miniers souterrains. Cette recherche vise à apporter une contribution majeure au domaine des systèmes de positionnement intérieur, spécifiquement adaptés aux défis et aux besoins du secteur minier.

CHAPITRE 1

ÉTAT DE L'ART :

La localisation dans des environnements souterrains sans GPS présente des défis similaires à la localisation intérieure, où les approches traditionnelles basées sur le comportement, les points de repère ou les capteurs denses peuvent être entravés par la décoloration du signal et des obstacles tels que les roches et le sol. Cependant, les techniques basées sur les informations d'état du canal offrent une solution prometteuse pour surmonter ces obstacles et améliorer la précision et la fiabilité de la localisation. Dans cette revue de littérature, nous explorerons l'état actuel de la recherche sur les techniques de localisation basées sur le CSI dans les environnements souterrains et intérieurs.

1.1. Un Système de Génération de Clés Sans Fil Piloté par ESP32 à Faible Coût Basé sur un Mécanisme de Réponse :

1.1.1. Aperçu :

Dans l'article suivant, les auteurs [11] proposent un système de génération de clés sans fil basé sur l'ESP32 et le mécanisme de réponse du protocole IEEE 802.11 pour extraire les informations de l'état du canal en vue d'une génération sécurisée de clés. L'approche vise à améliorer la réciprocité du CSI et à obtenir des clés identiques pour assurer la sécurité des communications sans fil.

1.1.2. Description du modèle et résultats :

Le système se compose de trois éléments principaux: la mesure du canal, la quantification, et la réconciliation de l'information. La mesure du canal implique l'interaction des trames de données pour obtenir les réponses fréquentielles du canal (CFR) des sous-porteuses. Une étape de prétraitement normalise l'amplitude et la phase du CSI, puis procède à la quantification en séquences de bits. La réconciliation de l'information utilise un mécanisme de correction d'erreur vers l'avant pour obtenir des clés finales. Des expériences ont été menées dans des environnements statiques et mobiles pour évaluer les performances du système. Les résultats ont révélé une réciprocity élevée du CSI dans divers scénarios, avec un taux de génération de clés d'environ 1788,23 bits/s. Cette approche a prouvé son efficacité et sa fiabilité pour la génération de clés sécurisées dans les communications sans fil.

1.2. Détection spatiale planifiée contre la détection WiFi adverse:

1.2.1. Aperçu :

Steven M. Hernandez et al. [12] ont proposé une solution novatrice pour contrer la détection WiFi adverse en utilisant des antennes émettrices spatialement distribuées. Leur approche vise à améliorer la précision des systèmes de détection WiFi en exploitant les variations de l'information d'état de canal. En mettant en avant l'utilisation de modèles d'apprentissage automatique pour prédire les activités physiques dans un environnement donné, leur étude souligne également les risques de sécurité associés à l'interception des signaux WiFi par des adversaires.

1.2.2. Description du modèle et résultats :

Le modèle proposé par Steven M. Hernandez et al. repose sur l'utilisation d'antennes émettrices spatialement distribuées pour améliorer la précision des systèmes de détection WiFi. Ce modèle utilise des réseaux neuronaux denses (DNN) pour prédire les activités physiques dans un environnement donné. Il est composé d'une couche d'entrée dense, de deux couches cachées denses et d'une couche de sortie dense. Pour éviter le surajustement du modèle, une régularisation de noyau L2 est appliquée à chaque couche dense, et une couche de désactivation est insérée entre chaque couche dense. L'optimisation de la fonction de perte est réalisée à l'aide de la Descente de Gradient Stochastique (SGD).

La configuration expérimentale comprend cinq émetteurs (TX) et un récepteur (RX) pour la détection des activités (Figure 1). Ces TX sont connectés au même dispositif source (D) via un commutateur d'antenne. Le planificateur (S) assume une fonction significative en décidant lequel des TX doit transmettre des données à un moment donné. En contrôlant le commutateur d'antenne, le planificateur détermine le TX spécifique qui sera actif pour la transmission, permettant au système de capturer et d'analyser les activités détectées dans l'environnement. Cette configuration permet au système de collecter des données à partir de différents TX de manière séquentielle, offrant une vue complète des activités physiques se déroulant dans la zone de détection.




Figure 1: Configuration expérimentale avec 5 émetteurs et 1 récepteur pour la détection d'activités

Les résultats des expériences ont révélé que l'exactitude des modèles d'apprentissage automatique développés à partir des données CSI provenant de chaque émetteur varie. Le TX-A affiche la plus haute précision à 84,6%, suivi de TX-C à 78,2%, TX-E à 70,1%, TX-B à 66,8%, et enfin TX-D à 64,5%. Par ailleurs, l'exactitude de l'espion (eavesdropper) diminue à mesure que le nombre de TXs utilisés dans un calendrier aléatoire augmente. Lorsqu'un seul TX est utilisé, l'exactitude est de 84,59%, mais elle diminue à 63,2% lorsque deux TXs sont impliqués, et encore plus bas lorsque trois, quatre ou cinq TXs sont utilisés, atteignant respectivement 55,7%, 51,9% et 47,1%. Ces résultats soulignent l'importance de la configuration des TXs et du calendrier de transmission dans la précision des modèles d'apprentissage automatique et dans la capacité de l'espion à effectuer une détection via le WiFi.

1.3. *Wi-CaL : Détection et localisation de foules sans dispositif via le WiFi et l'apprentissage automatique :*

1.3.1. Aperçu :

Hyuckjin Choi et al. [13] ont proposé une approche novatrice pour l'estimation de foules et la localisation sans dispositif en utilisant les signaux WiFi dans leur article. Ils ont développé le système Wi-CaL qui tire parti des variations des signaux WiFi pour détecter la densité et la position des personnes dans divers environnements sans nécessiter de dispositifs portés par les individus. Cette technique, qui combine des réseaux neuronaux convolutifs et des techniques de traitement du signal, permet une estimation précise de la foule et une localisation en temps réel, offrant ainsi des applications potentielles pour la gestion des espaces et la sécurité publique.

1.3.2. Description du modèle et résultats :

Le système Wi-CaL, ou (WiFi Sensing and Machine Learning Based Device-Free Crowd Counting and Localization), représente une approche novatrice qui se sert des informations de l'état des canaux WiFi pour compter et localiser les foules sans qu'il ne soit requis que les individus portent des appareils spécifiques. Ce modèle exploite des modules ESP32 pour créer des liaisons WiFi et extraire des caractéristiques pertinentes à partir des paquets CSI reçus, lesquelles sont par la suite employées pour évaluer la présence et la localisation des personnes à travers des techniques d'apprentissage machine classiques et profondes.

L'architecture de Wi-CaL englobe plusieurs étapes clés, commençant par la collecte

des signaux CSI à l'aide des modules ESP32 configurés en points d'accès et en stations. Le traitement des signaux inclut la segmentation des données ainsi que l'application de filtres pour réduire le bruit. Les caractéristiques extraites, telles que l'amplitude et la phase des signaux CSI, sont ensuite standardisées et fournies en entrée à des modèles d'apprentissage machine pour la prédiction du nombre de personnes et leur localisation dans différentes zones.



Figure 2: modules ESP32 dans une pièce test

Les performances du système Wi-CaL ont été évaluées à l'aide de divers modèles d'apprentissage machine et d'apprentissage profond afin de déterminer quelle méthode offre la meilleure efficacité en termes de précision de comptage et de localisation des foules. Les modèles testés incluent des régressions linéaires, des forêts aléatoires, ainsi que des architectures de réseaux de neurones profonds, comme XGBoost et LightGBM.

Les résultats expérimentaux révèlent que le modèle de régression XGBoost a démontré les performances les plus élevées, avec une erreur absolue médiane (MAE) de 0.35 pour le comptage des foules et une précision de localisation de 91.4% dans des espaces de petite taille avec cinq personnes. En comparaison, LightGBM a produit des résultats similaires avec une MAE de 0.41 et une précision de localisation de 98.1% dans des espaces de taille moyenne pouvant accueillir

jusqu'à dix personnes.

Ces résultats sont particulièrement remarquables lorsqu'ils sont mis en contraste avec les performances des approches utilisant des réseaux de neurones profonds (Deep Neural Networks, DNN), qui bien que légèrement supérieurs en termes de MAE (0.32 dans des espaces similaires), requièrent une capacité de calcul nettement plus élevée et des temps d'entraînement plus longs. Cela peut limiter leur applicabilité dans des environnements nécessitant une rapidité de déploiement et une faible consommation énergétique. Cette comparaison met en lumière les compromis entre précision et efficacité opérationnelle, suggérant que des modèles tels que LightGBM offrent un équilibre optimal pour des applications en temps réel.




Figure 3: Performance et comparaison entre les méthodes d'apprentissage

1.4. Amélioration de la localisation intérieure sans dispositifs basée sur l'information de l'état de canal (CSI) utilisant une approche de classification par apprentissage automatique :

1.4.1. Aperçu :

Dans leur étude intitulée "Amélioration de la localisation intérieure sans dispositif basée sur l'information de l'état du canal utilisant une approche de classification par apprentissage automatique", Tahsina Farah Sanam et al [14] explorent une nouvelle méthode de localisation intérieure qui dispense les individus du port d'un dispositif spécifique. Cette méthode tire parti des informations de l'état des canaux (CSI) obtenues à partir des systèmes MIMO-OFDM pour localiser les individus de manière passive à l'intérieur des bâtiments. En s'appuyant sur la diversité des fréquences et des emplacements des signaux CSI, les auteurs développent une technique capable de corréler la présence humaine à des modifications spécifiques des caractéristiques du signal reçu. Un des défis majeurs abordés par les chercheurs est le modelage précis de l'impact d'une personne sur le CSI, complexifié par les effets des multipath. Pour relever ce défi, ils proposent une méthode de sélection de sous-porteuses novatrice afin d'améliorer l'exactitude de la localisation. L'approche de localisation repose sur une classification par apprentissage profonds, transformant le problème de localisation en un problème d'identification de cellules à l'aide d'un classificateur SVM. Les résultats expérimentaux démontrent une grande précision de cette technique dans un environnement de test contrôlé, marquant ainsi une avancée significative dans le domaine de la localisation intérieure passive.

1.4.2. Description du modèle et résultats :

La technique de localisation mise en œuvre dans l'étude MaLDIP (Figure 4) a bien au-delà du simple suivi d'un individu à l'intérieur d'un espace ; elle métamorphose le défi en une question de classification cellulaire grâce à un modèle d'apprentissage automatique sophistiqué. Le choix d'un algorithme basé sur la machine à vecteurs de support (SVM) est central à cette approche. Le SVM est particulièrement adapté aux environnements complexes où les signaux CSI peuvent subir des fluctuations significatives, car il excelle dans la création de modèles de classification avec une large marge de séparation entre les classes prédictives. Cette robustesse est cruciale pour assurer que le système peut distinguer avec précision entre différentes zones ou cellules dans un espace intérieur malgré les perturbations du signal dues aux multipath et autres interférences.




Figure 4: Architecture de système

En termes de résultats, le système MaLDIP a prouvé une efficacité remarquable dans un contexte expérimental contrôlé. Les tests effectués dans un laboratoire

équipé d'un routeur sans fil ont révélé que MaLDIP pouvait localiser une personne dans une cellule spécifique avec une précision atteignant 98,27 %, utilisant un canal MIMO. Cette performance est supérieure à celle du système précédent, Pilot, qui n'avait atteint qu'une précision maximale de 90 % avec une configuration SISO (Figure 5). Cette amélioration substantielle découle de la stratégie de MaLDIP pour gérer minutieusement les réponses des canaux CSI. La sélection stratégique des sous-porteuses et l'emploi des caractéristiques PCA pour une réduction dimensionnelle efficace assure une fonction significative en rendant les données non seulement gérables mais aussi extrêmement précises pour la tâche de classification.




Figure 5: Performance des différents systèmes

1.5. CiFi : Réseaux Neuronaux Convolutionnels Profonds pour la Localisation Intérieure avec Wi-Fi 5GHz :

1.5.1. Aperçu :

Dans cette étude, les auteurs [15] exposent une méthode novatrice utilisant les données de phase de l'Information sur l'État du Canal (CSI) afin d'estimer l'Angle d'Arrivée (AOA), lequel est ultérieurement utilisé pour la localisation intérieure à l'aide de réseaux neuronaux convolutionnels profonds (DCNN). Cette approche tire parti des capacités de traitement des DCNN pour améliorer la précision de la localisation dans des environnements intérieurs complexes, marquant une avancée significative par rapport aux méthodes traditionnelles basées sur la force du signal reçu (RSS).

1.5.2. Description du modèle et résultats :

Le système CiFi exploite les différences de phase obtenues à partir des signaux Wi-Fi dans la bande des 5GHz pour créer des images estimées d'AOA qui servent d'entrées à un réseau de neurones convolutionnels profond. Le système comprend trois phases principales : la capture des données CSI, la transformation de ces données en images d'AOA, et l'utilisation de ces images pour entraîner le DCNN en phase hors ligne. Une fois formé, le DCNN peut prédire la localisation des appareils mobiles avec une grande précision, utilisant de nouvelles images AOA générées à partir des données capturées en temps réel.

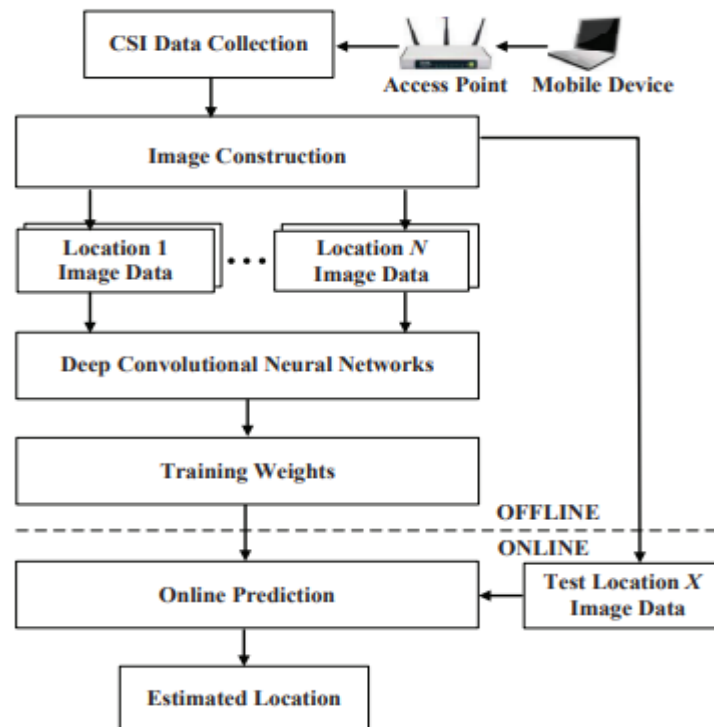


Figure 6: Architecture de système CiFi

Les expérimentations du système CiFi ont été menées dans deux environnements intérieurs différents, démontrant une amélioration notable de la précision de localisation par rapport aux systèmes existants. CiFi a réussi à réduire significativement l'erreur de localisation, atteignant une précision allant jusqu'à 98,27% (Figure 7) dans un environnement de laboratoire informatique. Ces performances sont attribuées à la capacité du DCNN à extraire et à apprendre des caractéristiques robustes à partir des images AOA, offrant une résilience notable contre les perturbations environnementales comme les interférences multipath.




Figure 7: Fonction de Distribution Cumulative des erreurs de localisation pour l'expérience en laboratoire

CHAPITRE 2

MATÉRIELS ET LOGICIELS :

2.1.Aperçus :

L'estimation précise de la localisation demeure une préoccupation de premier plan dans divers domaines d'application, tels que la robotique, la navigation et la surveillance. Dans cette perspective, l'état du canal sans fil émerge comme une stratégie incontournable, permettant d'agréger des données riches pour obtenir une estimation plus fiable de la localisation [16]. Cette approche est largement adoptée afin de pallier les limitations des méthodes de localisation traditionnelles et d'améliorer la précision globale du processus.

Nous avons développé un système de positionnement intérieur économique capable d'assurer un suivi de haute précision même avec des dispositifs WiFi dotés d'une seule antenne, évitant ainsi la nécessité d'un réseau d'antennes complexe [17]. L'ESP32, au cœur de notre système, exploite les informations bidirectionnelles sur l'état du canal disponibles sur l'ensemble des canaux WiFi pour calculer la distance entre les nœuds.

2.2.Matériels :

Au départ de notre projet de recherche, nous avons adopté l'utilisation des cartes réseau NIC5300 (figure 8) pour la collecte des données CSI, un choix dicté par leur utilisation répandue dans l'analyse des systèmes de communication sans fil. Cependant, en raison de problèmes de défaillance matérielle, nous avons dû nous orienter vers une solution alternative qui garantirait la continuité et la fiabilité de notre

recherche. C'est dans ce contexte que nous avons sélectionné les modules ESP32 (figure 12), connus pour leur stabilité et leur polyvalence. L'infrastructure mise en place s'articule autour de trois modules ESP32 distincts : le premier configuré en tant que point d'accès (AP), le second agissant en tant que station (STA), et le troisième module déployé pour capturer de manière passive les échanges CSI entre l'AP et la STA. Cette configuration nous a permis de simuler un environnement réseau contrôlé et cohérent, tout en maintenant une puissance de transmission constante, ce qui est crucial pour l'acquisition de données fiables et précises.

2.2.1. Carte WiFi NIC5300

Pour notre expérimentation, nous utilisons deux ordinateurs portables Lenovo équipés d'adaptateurs réseau Intel Wi-Fi Link (IWL) 5300 NIC, chacun doté de trois antennes [18]. Ces trois antennes permettent de créer neuf liaisons sans fil entre le point d'accès (AP) et la station mobile (MS). De plus, afin d'obtenir une couverture avec une portée plus longue, nous avons choisi la bande de fréquence de 2,4 GHz, ce qui confère au signal une longueur d'onde d'environ 12,5 centimètres. Par ailleurs, le mode de fonctionnement de cette connexion est configuré en "mode moniteur", où les paquets sont envoyés et reçus à une adresse codée en dur, 00:16:ea:12:34:56. Dans cette recherche, toutes les neuf liaisons entre Tx1-3 et Rx1-3 sont prises en compte pour exploiter la diversité spatiale.

La raison pour laquelle cet adaptateur réseau spécifique est utilisé est qu'il permet l'accès aux données CSI grâce à l'installation d'un pilote modifié créé par Daniel Halperin [19]. Ce firmware modifié remplace le noyau précédent du système d'exploitation Linux Ubuntu par une version personnalisée. Ce noyau personnalisé active le mode de débogage de l'adaptateur réseau, et par conséquent, à chaque session de communication entre deux machines, un rapport CSI contenant un nombre ajustable de paquets pour 30 groupes de sous-porteuses (un groupe pour chaque 2

sous-porteuses à 20 MHz) est reçu par la machine réceptrice à la suite d'une demande envoyée par cette dernière. L'ensemble des CSI obtenues représente le comportement unique et indépendant du temps pour chaque emplacement. Ces données constituent la signature appropriée pour la technique de l'empreinte digitale.

À la suite de notre travail initial avec les deux cartes réseau, les résultats ont été sensiblement altérés par des défaillances liées aux cartes elles-mêmes et à leurs antennes. Confrontés à ces contraintes techniques, nous avons constaté une grande variabilité dans les données collectées, ce qui a compromis la fiabilité de nos mesures de localisation. Ces imprécisions nous ont menés à réévaluer l'approche matérielle de notre projet. Après une analyse approfondie des options disponibles, nous avons décidé de nous orienter vers l'utilisation des microcontrôleurs ESP32. Ces dispositifs offrent non seulement une stabilité accrue par rapport aux configurations précédentes, mais également une meilleure adaptabilité aux exigences de notre recherche en termes de traitement des signaux et de gestion des données CSI. L'ESP32, avec sa capacité à gérer efficacement plusieurs tâches simultanément et sa compatibilité avec divers environnements de développement, nous est apparu comme la solution idéale pour surmonter les défis techniques rencontrés et pour poursuivre notre étude sur des bases plus solides.



Figure 8: Carte NIC5300

2.2.2. Esp32

L'ESP32, microcontrôleur intégré, est vénéré pour sa versatilité et son coût réduit, ce qui le rend spécialement approprié aux applications nécessitant une localisation précise à budget limité. Il fusionne la connectivité WiFi et Bluetooth en un seul module compact, offrant ainsi une solution idéale pour le développement de systèmes embarqués intelligents. L'ESP32 est également équipé de diverses fonctionnalités avancées, telles que des capteurs intégrés, des interfaces d'entrée/sortie multiples, et une pile protocolaire complète qui supporte les normes WiFi 802.11 b/g/n/e/i. Sa capacité à collecter et à traiter les informations de l'état du canal le qualifie remarquablement pour les applications de localisation, exigeant un haut degré de précision. En somme, l'ESP32 se distingue émerge comme un choix économique judicieux en quête de solutions de localisation robustes tout en préservant une performance optimale.

Le Wi-ESP, utilisé comme outil de mesure et de traitement de l'information sur l'état du canal (CSI), tient un rôle central dans les applications de détection sans dispositif via Wi-Fi (DFWS) [20]. L'ESP32, qui intègre le protocole de contrôle de transmission/protocole Internet (TCP/IP) et le protocole d'accès au support de réseau local sans fil (WLAN) 802.11 b/g/n/e/i complet, est apte à communiquer avec la plupart des routeurs Wi-Fi en mode station (client). De plus, il peut également fonctionner comme un point d'accès (AP), utilisant pleinement le protocole MAC WLAN 802.11 b/g/n/e/i. Cette polyvalence confère à l'ESP32 la capacité de fonctionner sans nécessiter de dispositifs de transmission (TX) ou de réception (RX) spécifiques pour les mesures de CSI, étant donné qu'il peut imiter à la fois un émetteur et un récepteur. L'outil ESP32 fournit des informations de canal précises et détaillées ainsi que des mesures de CSI de tous les 52 sous-porteuses dans le domaine fréquentiel, ce qui s'avère essentiel pour les applications DFWS.

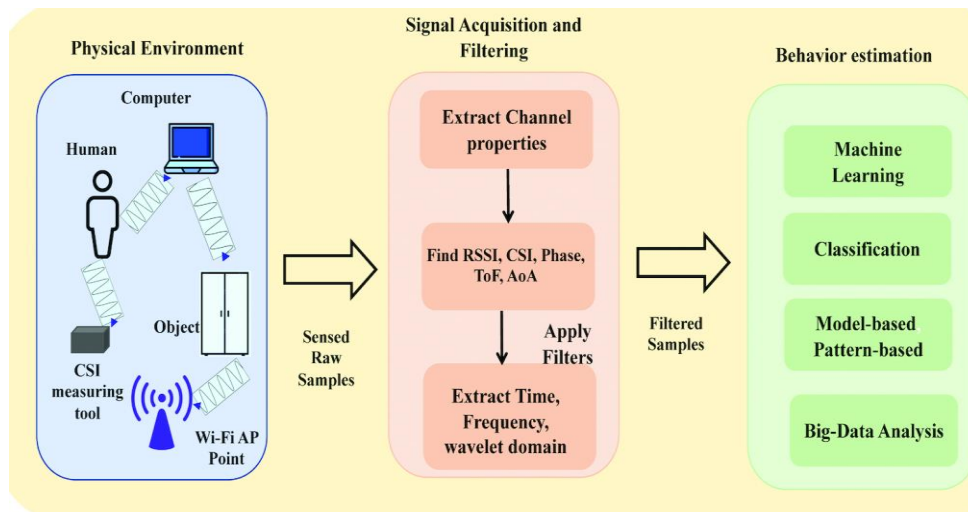


Figure 9: Concept de détection Wi-Fi sans dispositif (DFWS)

2.3. Logiciels :

Dans le cadre de notre recherche, nous avons recouru à divers langages de programmation ainsi qu'à des environnements de développement distincts, sélectionnés en fonction des appareils utilisés et des objectifs spécifiques de chaque phase du projet. Initialement, lors de l'utilisation des cartes réseau Intel Wi-Fi Link (IWL) 5300 NIC, nous avons opté pour l'utilisation du logiciel Matlab pour traiter et analyser les données. Cette plateforme offre un éventail complet d'outils analytiques, particulièrement adaptés à la manipulation de données complexes et à la modélisation mathématique.

Par la suite, avec l'introduction des microcontrôleurs ESP32 dans notre étude, nous avons basculé vers le langage Python, reconnu pour sa simplicité et son efficacité en matière de développement rapide d'applications. Pour ce faire, nous avons fait usage de l'IDE (environnement de développement intégré) Visual Studio, qui facilite la gestion de projets complexes et l'intégration de diverses bibliothèques. Parmi celles-ci, nous avons incorporé la bibliothèque ESP-IDF d'espressif, qui fournit les

outils et le SDK nécessaires pour développer des applications software sur l'architecture ESP32.

Pour la programmation des ESP32 en tant que points d'accès et stations, nous nous sommes appuyés sur des scripts disponibles sur GitHub [21]. Ces scripts fournissent une base solide pour programmer les dispositifs ESP32 afin qu'ils fonctionnent en mode point d'accès ou en mode station, facilitant ainsi la mise en place de communications réseau dans notre système de localisation. Après avoir cloné les scripts requis, nous avons procédé à la configuration des paramètres réseau spécifiques à notre application et généré le code pour déployer notre solution de localisation.

CHAPITRE 3

ÉTAT DE CANAL SANS FILS :

3.1. Introduction :

Dans le cadre de l'étude des communications sans fil, la compréhension approfondie du comportement du signal à travers le canal de transmission ressort d'une importance prépondérante. L'analyse de l'état du canal s'impose ainsi comme un pilier central de cette exploration, prodiguant des insights détaillés sur les divers aspects qui affectent la transmission des signaux. Le CSI permet de décomposer et d'analyser les multiples facettes de l'environnement de transmission, facilitant ainsi l'optimisation des stratégies de communication. Cette analyse se focalise sur plusieurs éléments clés du comportement du signal, chacun concourant à une meilleure compréhension et gestion des dynamiques complexes du canal. Ces éléments se révèlent fondamentaux pour le développement de systèmes de communication robustes et efficaces, adaptés aux défis spécifiques posés par les environnements de transmission variés, qui rend la localisation plus efficace. Voici quelques points fondamentaux que le CSI contribue à élucider :

1. **Analyse du Signal par le CSI:** Le CSI procure une analyse profonde des effets du canal sur le signal, tels que les changements d'amplitude causés par l'atténuation, au fading causé par les obstacles ou les phénomènes météorologiques, ainsi que les modifications de phase dues aux différences de trajet empruntés par les ondes radio. L'analyse de ces variations s'avère primordial pour adapter les techniques de transmission telles que le choix de la puissance d'émission, la sélection du schéma de modulation, et le taux de codage.

2. Le multipath et ses conséquences: Dans des environnements complexes, les signaux peuvent emprunter plusieurs chemins avant d'atteindre le récepteur, donnant lieu à un phénomène nommé propagation multipath. Le CSI permet de caractériser la dispersion temporelle des signaux (également connue sous le nom de délai de propagation), qui représente la différence de temps d'arrivée entre les diverses composantes multipath. Cela renseigne sur la présence et l'intensité des réflexions, réfractions et diffractions rencontrées par le signal.
3. Le Spectre de cohérence du Canal: Le CSI permet également d'évaluer le degré de variabilité du canal sur les plans temporel et fréquentiel, c'est-à-dire la rapidité avec laquelle le canal peut modifier ses caractéristiques. La compréhension de cette cohérence est cruciale pour déterminer la fréquence des mises à jour requises du CSI afin de garantir une communication fiable.
4. La réponse impulsionnelle et fréquentielle du canal : Le CSI se matérialise souvent par la réponse impulsionnelle du canal (CIR) et la réponse fréquentielle du canal (CFR). La CIR décrit la façon dont un signal delta est affecté par le canal, offrant une perspective temporelle des changements d'amplitude et de phase subis par le signal. La CFR, obtenue par la transformation de Fourier de la CIR, fournit une perspective fréquentielle, illustrant comment le canal affecte les différentes fréquences du spectre du signal.

$$CIR = h(\tau) = \sum_{i=1}^N \alpha_i e^{-j\theta_i} \delta(\tau - \tau_i) \quad (1)$$

$$CFR = h(\omega) = FFT(H(\tau)) = \sum_{i=1}^N \alpha_i e^{-j(\omega\tau_i + \theta_i)} \quad (2)$$

Où α_i , θ_i , τ_i et N représentent respectivement l'amplitude, la phase, le délai pour chaque signal sur le nième chemin, et le nombre total de chemins.




Figure 10: L'amplitude de CFR de 5 paquets pour 1 seul point de mesure




Figure 11: L'amplitude de CIR de 5 paquets pour 1 seul point de mesure

La collecte et l'exploitation du CSI sont réalisées par des techniques sophistiquées, telles que l'utilisation de préambules et séquences de sondage spécialement conçues, qui, une fois reçues, permettent d'estimer l'état du canal via des méthodes telles que les estimations de type erreur quadratique moyenne (MSE) et erreur absolue moyenne (MAE).

L'interprétation avancée du CSI, qui peut être enrichie par des techniques d'apprentissage automatique et d'intelligence artificielle, ouvre des perspectives prometteuses pour l'adaptation en temps réel des stratégies de transmission sans fil. Ainsi, le CSI est au cœur des stratégies d'optimisation de l'efficacité spectrale, de l'amélioration de la couverture du signal, de l'accroissement de la capacité des réseaux et de la réduction des interférences, jouant un rôle déterminant dans la performance et la fiabilité des systèmes de communication modernes.

3.2. Installation et Configuration Matérielle :

Pour notre projet de localisation souterraine utilisant l'intelligence artificielle, une configuration matérielle robuste et méticuleuse a été mise en place au sein de la mine 'La Cité de l'Or' à Val-d'Or, Canada. Trois modules ESP32 ont été déployés, chacun ayant un rôle spécifique dans la capture et l'analyse des données CSI, qui sont essentielles pour la précision de la localisation. Le premier module a été configuré en tant que point d'accès (AP) pour émettre le signal. Le deuxième module, agissant en tant que station (STA), a été fixé à une distance déterminée de l'AP pour recevoir le signal transmis. Le troisième module ESP32, installé en mode passif, était chargé d'enregistrer les informations échangées entre l'AP et la STA, capturant ainsi les variations subtiles des données CSI en temps réel.

L'installation physique des modules a exigé une attention rigoureuse quant à leur position et orientation pour s'assurer que les conditions de transmission entre l'AP et

la STA soient optimales. Ces modules ont été positionnés à une hauteur de deux mètres pour l'AP et la STA, afin de minimiser les interférences et d'imiter les conditions de propagation réelles que l'on pourrait trouver dans des applications de localisation commerciales. Le module passif a été placé à une hauteur d'un mètre pour fournir une perspective différente de la collecte des données CSI. Tous les modules ont été alimentés par des sources d'énergie fiables et disposés de manière à éviter toute obstruction susceptible d'altérer la qualité des données.

Pour l'acquisition des données CSI, notre système a été méticuleusement configuré pour opérer à une fréquence de 2.4 GHz avec une bande passante de 40 MHz, en s'appuyant sur le Long Training Field (LLTF) du préambule Wi-Fi 802.11n pour une estimation précise du canal. Nous avons privilégié la technique de modulation Binary Phase Shift Keying (BPSK) pour sa simplicité et sa robustesse, ce qui nous a permis de garantir un débit de données stable de 6 Mbps. La puissance de transmission a été optimisée à 20 dBm, avec un gain d'antenne de 3 dBi, afin d'assurer une force de signal robuste à travers tous les points de mesure de notre grille expérimentale. La phase de collecte de données a été marquée par une attention scrupuleuse envers l'enregistrement des valeurs d'amplitude et de phase pour chacune des 64 sous-porteuses OFDM, en s'appuyant sur les informations fournies par le LLTF. Dans notre ensemble de données, nous avons observé que sur les 64 sous-porteuses disponibles, 52 ont transmis activement de l'énergie, tandis que les douze restantes sont inutilisées, probablement dédiées à des fonctions telles que les bandes de garde ou les tonalités pilotes (figure 10).

La fréquence de sous-porteuse, essentielle pour la résolution temporelle de notre analyse, est calculée par la formule:

$$\Delta f = \frac{BW}{N} = \frac{40 \times 10^6}{64} = 625000 \text{ Hz} \quad (3)$$

Où BW représente la bande passante et N le nombre de sous-porteuses. Cela établit un intervalle d'échantillonnage (T_s) de:

$$T_s = \frac{1}{\Delta f} = 1.6 \times 10^{-6} \text{ s} \quad (4)$$

L'intervalle d'échantillonnage, ou le temps entre chaque échantillon dans notre signal de temps après IFFT, est l'inverse de la fréquence de sous-porteuse.

La durée totale du signal affiché sur la figure 11 est de $100 \mu\text{s}$, déterminée par:

$$T = N \times T_s = 64 \times 1.6 \times 10^{-6} = 0.0001024 \text{ s} \quad (5)$$

La durée du signal de 102.4 microsecondes est très proche de 100 microsecondes. Cela signifie que la figure 11 que nous avons montrée est configurée pour afficher la durée totale du signal calculé, ce qui correspond à la durée de l'impulsion résultant de notre IFFT.

Cette récolte méticuleuse de données a été essentielle pour construire un profil détaillé du comportement du canal, qui s'est avéré être la pierre angulaire de notre analyse avancée de localisation par intelligence artificielle. En somme, notre passage des cartes NIC5300 aux modules ESP32 ne représente pas seulement une adaptation due à des contraintes techniques, mais marque une évolution significative dans la méthodologie de notre recherche. Les ESP32 offrent une plateforme solide pour une exploration approfondie de la communication sans fil dans les environnements complexes, et leur flexibilité nous permet d'envisager des perspectives de recherche élargies, notamment dans le domaine de la localisation de précision soutenue par les avancées de l'intelligence artificielle.

Dans cette optique, une attention particulière a été accordée à la collecte des données. À chaque point de mesure, notre système a été conçu pour capter au minimum 50 paquets de CSI (ANNEX A) par seconde, conformément à la configuration de débit

de paquets prédéfinie pour nos modules ESP32. Cette cadence de collecte élevée est impérative pour assurer la consistance et la fiabilité des données recueillies, qui sont cruciales pour une analyse précise de l'information sur l'état du canal (CSI). Les modules ESP32 ont été stratégiquement configurés pour servir des rôles spécifiques : deux d'entre eux, l'un agissant en tant que point d'accès (AP) et l'autre en tant que station (STA), ont été installés à une hauteur optimale de deux mètres. Cette hauteur a été choisie pour favoriser une propagation claire du signal, réduisant ainsi les interférences et reflétant fidèlement les conditions réelles de transmission. Le troisième module, positionné en mode passif à un mètre de hauteur, a pour fonction de capter les interactions CSI entre l'AP et la STA, a fourni des informations complémentaires vitales pour notre étude.




Figure 12: Notre version de esp avec les antennes externes

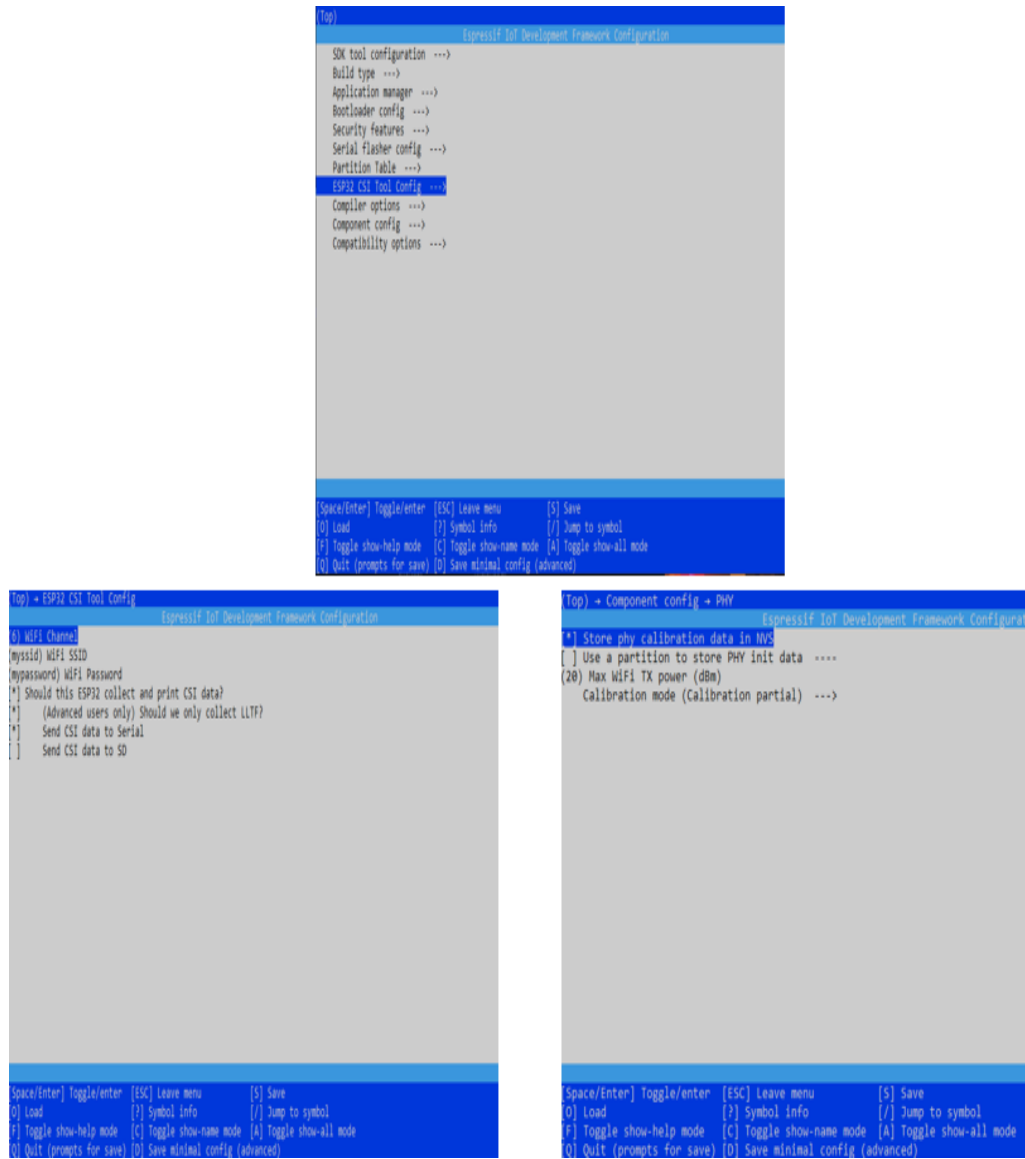


Figure 13: Photographie des configurations pour les Esp32

```

I (7430) wifi:new:<6,1>, old:<6,0>, ap:<255,255>, sta:<6,1>, prof:6
I (7440) wifi:state: init -> auth (b0)
I (7440) wifi:state: auth -> assoc (0)
I (7450) wifi:state: assoc -> run (10)
I (7550) wifi:connected with myssid, aid = 1, channel 6, 40U, bssid = a8:42:e3:4c:c4:99
I (7550) wifi:security: WPA2-PSK, phy: bgn, rssi: -68
I (7550) wifi:pm start, type: 0

I (7590) wifi:AP's beacon interval = 102400 us, DTIM period = 2

```

Figure 14: L'envoi des paquets de AP

```

CSI_DATA,Passive,64:B7:08:C4:9C:F0,-16,11,0,0,0,0,0,0,0,0,-96,0,1,1,2201393,0,28,0,0,2.56536,128,[28 -64 1 0 0 0 0 0 0 0 0 0
CSI_DATA,Passive,64:B7:08:C4:9C:F0,-16,11,0,0,0,0,0,0,0,0,-96,0,1,1,2204116,0,157,0,0,2.60812,128,[-99 -48 9 0 0 0 0 0 0 0 0 0
CSI_DATA,Passive,64:B7:08:C4:9C:F0,-16,11,0,0,0,0,0,0,0,0,-96,0,1,1,2296023,0,135,0,0,2.66004,128,[-121 112 8 0 0 0 0 0 0 0 0 0
I (3228) Active CSI collection (Passive): station 64:b7:08:c4:9c:f0 join, AID=2
CSI_DATA,Passive,C2:F4:59:75:71:79,-38,9,0,0,0,0,0,0,0,0,-96,0,1,1,2450625,0,28,0,0,2.81441,128,[28 -64 1 0 0 0 0 0 0 0 0 0 1
CSI_DATA,Passive,C2:F4:59:75:71:79,-38,9,0,0,0,0,0,0,0,0,-96,0,1,1,2472913,0,28,0,0,2.84852,128,[28 -64 1 0 0 0 0 0 0 0 0 0 6
CSI_DATA,Passive,64:B7:08:C4:9C:F0,-26,11,1,7,1,1,0,0,0,1,-96,0,1,1,2798598,0,390,0,0,3.16212,384,[-122 -31 23 0 0 0 0 0 0 0 0 0
CSI_DATA,Passive,64:B7:08:C4:9C:F0,-26,11,1,7,1,1,0,0,0,1,-96,0,1,1,2839919,0,390,0,0,3.20346,384,[-122 -31 23 0 0 0 0 0 0 0 0 0

```

Figure 15: Visualisation des CSI d'Esp passive

3.3. *Wi-Fi* :

Le Wi-Fi, abréviation de "Wireless Fidelity", est une technologie de communication sans fil octroyant aux appareils électroniques de se connecter à Internet et de communiquer entre eux via des ondes radio. Il est devenu omniprésent dans nos vies, offrant une connectivité sans fil à la maison, au bureau, dans les cafés, les aéroports, et d'innombrables autres lieux.

Les normes Wi-Fi évoluent sans relâche pour offrir des performances accrues. La norme 802.11ax (Wi-Fi 6) se dresse parmi les plus récentes versions, dispensant des vitesses plus rapides, une gestion plus éclairée des appareils connectés et une efficacité accrue.

Le Wi-Fi utilise des canaux radio pour transmettre des données. Ces canaux correspondent à des plages spécifiques de fréquences radio. Plus la fréquence se montre élevée, plus la capacité de transmission de données s'avère grande, néanmoins la portée se trouve plus limitée. C'est pourquoi les routeurs Wi-Fi proposent généralement des bandes de fréquences de 2,4 GHz et 5 GHz, chacune détenant ses avantages et ses inconvénients en termes de portée et de vitesse.

Dans le cadre de notre recherche, nous avons recouru à la norme 802.11n du Wi-Fi, également connue sous le nom de Wi-Fi 4, conjointement à la modulation BPSK (Modulation par déphasage binaire). La norme 802.11n est une norme établie pour les réseaux sans fil qui offre des améliorations notables en termes de vitesse et de performance par rapport aux normes précédentes. Elle permet d'atteindre des débits de données plus élevés, et une couverture sans fil améliorée.

La modulation BPSK est l'une des techniques de modulation employées dans la norme 802.11n. Elle repose sur la modification de la phase du signal porteur pour représenter des bits d'information. La modulation BPSK est reconnue pour sa simplicité et sa résistance au bruit, ce qui est, en fait, un choix approprié pour les environnements sans

fil où la fiabilité de la transmission des données est essentielle.

3.4.RSSI :

Le RSSI, ou "Received Signal Strength Indicator", est une mesure de la puissance du signal radio reçu par un dispositif sans fil, habituellement exprimé en décibels-milliwatts (dBm). Il indique à quel point le signal est fort ou faible lorsqu'il est capté par l'antenne du récepteur.

Le RSSI est une mesure essentielle pour évaluer la qualité de la connexion sans fil. Plus le RSSI est élevé (moins négatif), plus le signal est fort et la connexion est probablement stable. En revanche, un RSSI plus bas signifie un signal plus affaibli, susceptible d'entraîner une connexion moins fiable ou une vitesse de transmission plus lente.

Il convient de souligner que le RSSI, en lui-même, ne fournit pas toujours une image complète de la qualité de la connexion Wi-Fi. D'autres facteurs, tels que le bruit du signal, les interférences et la qualité de l'antenne, peuvent également influencer la performance du réseau sans fil.

En résumé, le Wi-Fi est une technologie de communication sans fil largement utilisée, tandis que le RSSI est une mesure de la force du signal reçu qui aide à évaluer la qualité de la connexion sans fil. Pour une connexion Wi-Fi fiable, il est impératif de prendre en considération à la fois le RSSI et d'autres facteurs susceptibles d'impacter la qualité du signal.

Les informations sur l'état du canal, communément désignées sous l'acronyme CSI pour, fournissent une représentation minutieuse des propriétés du canal de transmission dans les systèmes de communication sans fil. Le CSI est crucial pour l'ajustement dynamique des paramètres du système de communication afin d'optimiser la qualité de la liaison sans fil face aux diverses altérations et perturbations que le signal peut subir durant sa propagation.

3.5.L'environnement des mesures :

Notre projet de recherche, mené dans le cadre unique de la mine 'La Cité de l'Or' située à Val-d'Or au Canada, s'est distingué par une approche méthodique et innovante dans le domaine de la localisation souterraine. L'objectif principal est de cartographier avec précision les signaux dans un environnement aussi complexe et changeant que celui d'une mine souterraine. À cette fin, un réseau exhaustif de points de mesure a été soigneusement déployé à travers les galeries de la mine, avec chaque point espacé de manière régulière à 0.5 mètre l'un de l'autre. Cette configuration en grille, conçue pour couvrir une étendue considérable de l'espace souterrain, est essentielle pour obtenir une visualisation détaillée et exhaustive de la propagation des signaux dans diverses conditions géologiques et structurelles propres à l'environnement minier.

L'importance de cette photographie, que nous insérons dans notre rapport, réside dans sa capacité à illustrer visuellement l'étendue et la profondeur de notre projet sur le terrain. Elle montre non seulement l'environnement de test au sein de la mine, mais met également en exergue la répartition stratégique et l'agencement précis des points de mesure. Cette image, en offrant un aperçu concret de la méthodologie expérimentale mise en œuvre, souligne l'ampleur du travail réalisé. Elle met en évidence chaque détail de la configuration, depuis la distance exacte entre les points de mesure jusqu'à la fréquence de réception des paquets, le tout ayant été méticuleusement planifié pour maximiser la qualité et la précision des données recueillies.

En somme, cette visualisation est indispensable pour comprendre non seulement la complexité du processus de collecte de données, mais également l'engagement rigoureux de notre équipe à exploiter les capacités avancées de l'intelligence artificielle. Elle témoigne de notre volonté d'apporter une contribution significative à la localisation précise dans des environnements souterrains complexes, un défi majeur dans le domaine de la géolocalisation.

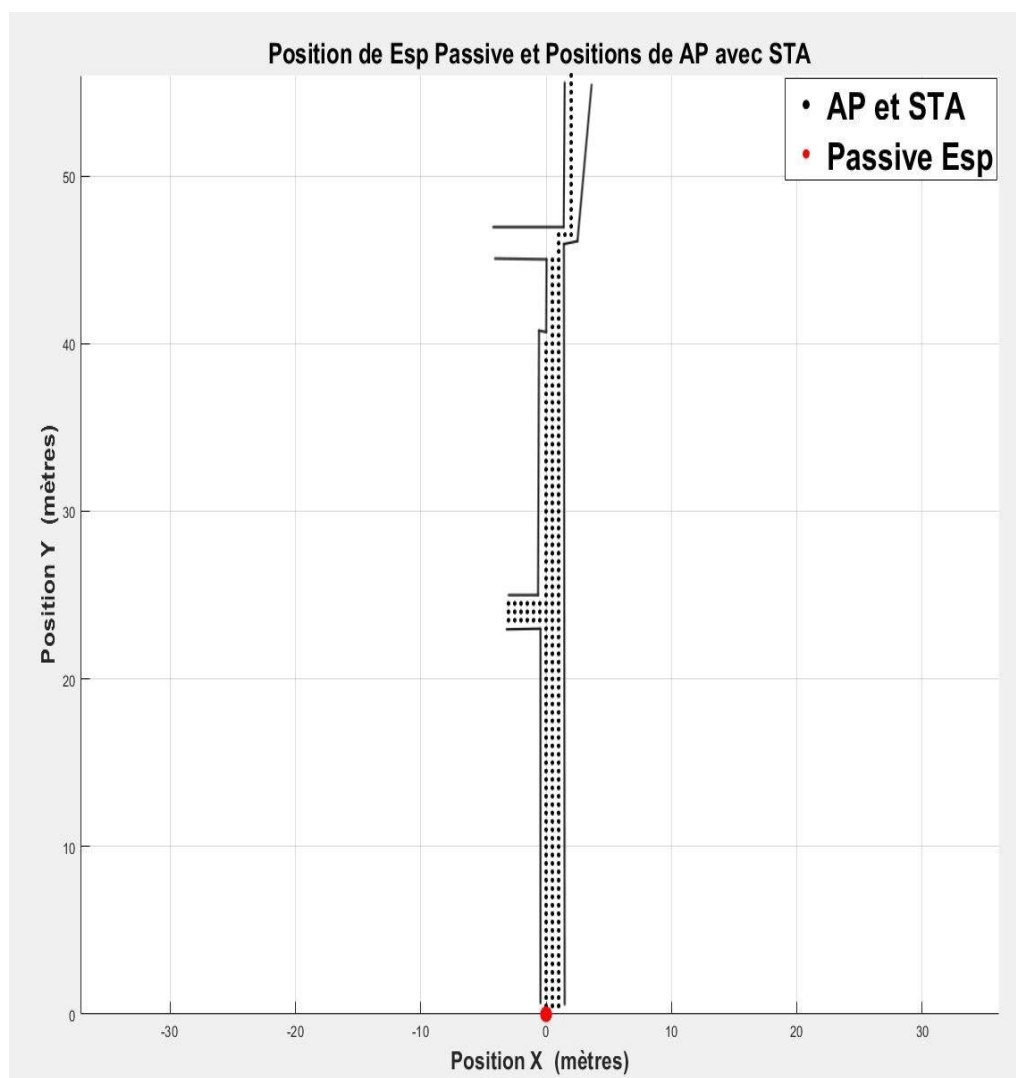


Figure 16: Position de Esp passive et position de AP et STA (mine)



Figure 17: Photographie de galerie de mine

3.6. Les Paramètres pertinents du canal :

Dans notre projet actuel, nous avons adopté une approche directe et efficace pour la localisation souterraine, en utilisant les informations brutes du canal de

communication, telles que les amplitudes et les phases, ainsi que les valeurs de RSSI (Received Signal Strength Indicator). Cette méthode se concentre sur l'exploitation des données de l'état du canal dans leur forme la plus élémentaire pour déterminer la position exacte dans l'environnement de la mine. En capturant ces données directement depuis les signaux transmis et reçus par les modules ESP32, nous avons pu construire un modèle précis de l'état du canal de communication, élément crucial pour la localisation précise dans un milieu aussi complexe et variable qu'une mine souterraine.

Cependant, au-delà de l'analyse directe des amplitudes, des phases et des RSSI, notre étude a également révélé l'importance cruciale des paramètres de délai du canal, en particulier le délai RMS (Root Mean Square Delay Spread) et le délai moyen. Ces paramètres de délai offrent une compréhension plus profonde de la dynamique du canal et sont essentiels pour comprendre comment les signaux sont affectés pendant leur transmission à travers le milieu souterrain.

1. Le Délai RMS (Root Mean Square Delay Spread):

Le délai RMS constitue une mesure statistique clé utilisée servant à quantifier la dispersion temporelle des signaux dans un canal de communication multipath. Mathématiquement, il se définit comme la racine carrée de la moyenne pondérée des carrés des écarts de chaque trajet par rapport au délai moyen. Dans notre étude, le délai RMS est calculé à partir de la réponse impulsionnelle du canal, dérivée par la transformation de Fourier inverse (IFFT) de la réponse en fréquence (CFR). Cette valeur reflète la diversité temporelle du canal et est essentielle pour évaluer l'impact du multipath sur la performance du système de communication.

$$\tau_{RMS} = \sqrt{\frac{\sum |h(\tau_i)|^2 (\tau_i - \bar{\tau})^2}{\sum |h(\tau_i)|^2}} \quad (6)$$

Où $h(\tau_i)$ représente la réponse impulsionnelle du canal à l'instant τ_i , et $\bar{\tau}$ est le délai moyen pondéré par l'énergie. Le délai RMS est une mesure de la dispersion des trajets multiples que le signal radio peut emprunter, engendrant réflexions et réfractions. Une valeur élevée de délai RMS indique une grande dispersion multipath, susceptible de générer des interférences et affecter la qualité du signal.

2. Délai moyen:

Le délai moyen, quant à lui, représente le retard moyen des trajets du signal par rapport au trajet le plus rapide. Ce paramètre est calculé comme la moyenne pondérée des retards de chaque trajet, pondérée par la puissance de ces trajets. Le délai moyen est un indicateur considérable de la latence induite par le canal et remplit un rôle décisif dans l'évaluation de la performance du système en présence de multipath. Dans notre approche, cette mesure est également obtenue à partir de la réponse impulsionnelle du canal.

$$\bar{\tau}_{excess} = \frac{\sum |h(\tau_i)|^2 \tau_i}{\sum |h(\tau_i)|^2} - \bar{\tau} \quad (7)$$

Cette métrique fournit une moyenne pondérée du retard de chaque composant multipath par rapport au premier trajet (le plus rapide) du signal. Un Mean Excess Delay élevé indique que la majorité des composants multipath arrivent significativement plus tard que le premier trajet, ce qui peut impacter négativement

la cohérence du signal reçu.

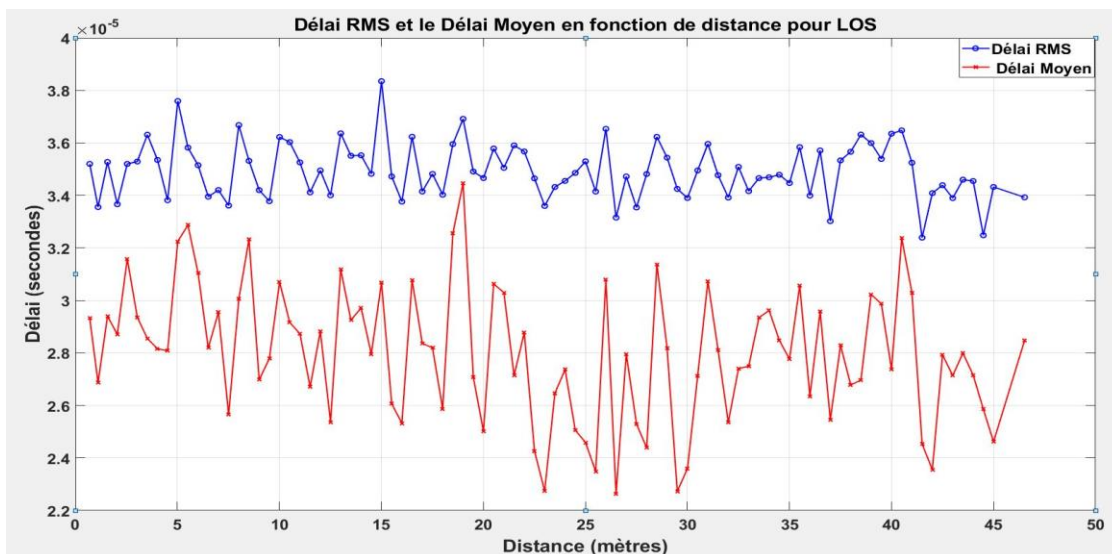


Figure 18 : Délag RMS et délag moyen en fonction de distance pour ligne de visée




Figure 19 : Délag RMS et délag moyen en fonction de distance pour non-ligne de visée

1. Pour le délai RMS :

Dans des conditions LOS, le délai RMS est généralement plus faible et plus stable car les signaux voyagent par le trajet le plus direct sans rencontrer d'obstacles significatifs. Cependant, même dans ces conditions, la présence de petites fluctuations peut indiquer des réflexions et des diffractions mineures dans l'environnement minier. Le graphique LOS montre une certaine variabilité du délai RMS avec la distance, mais cette variabilité reste relativement faible, indiquant un environnement de propagation relativement cohérent et prévisible.

Dans des conditions NLOS, le délai RMS tend à être plus élevé et à présenter une variabilité beaucoup plus grande, comme illustré par le graphique NLOS. Cela s'explique par de multiples obstacles et réflexions qui caractérisent les signaux dans ces conditions, où ils peuvent être réfléchis, diffractés ou dispersés par diverses structures souterraines.

Cette plus grande variabilité et ces valeurs accrues du délai RMS dans les conditions NLOS suggèrent une complexité accrue dans le profil de propagation du signal. La présence de pics et de creux marqués dans le graphique NLOS peut être attribuée à des changements spécifiques dans l'environnement, tels que des intersections de tunnels ou des zones avec des matériaux de composition variée, qui affectent la propagation des ondes radio.

2. Pour le délai moyen (Mean Excess Delay) :

Le délai moyen mesure le retard moyen, pondéré, de tous les trajets par rapport au trajet direct. Sous conditions LOS, on s'attendrait à ce que le délai moyen soit relativement faible, du fait de la moindre occurrence de trajets indirects contribuant au signal reçu. Sur le graphique LOS, nous observons une certaine consistance avec

une légère augmentation du Mean Excess Delay avec la distance, ce qui pourrait refléter une augmentation de la dispersion temporelle due à l'élargissement du faisceau avec l'augmentation de la distance.

En revanche, dans les conditions NLOS, le délai moyen est plus susceptible de présenter des valeurs élevées et variables, reflétant la présence de nombreux trajets indirects avec des retards significatifs. Le graphique NLOS expose clairement cette tendance, avec des valeurs de délai moyen bien plus élevées et irrégulières, mettant en lumière l'impact des obstacles et des réflexions multiples sur les trajets des signaux.

3.7. Calibration de notre système :

La calibration de notre système de mesure de signal sans fil est une étape essentielle pour garantir la précision et la fiabilité des applications de localisation souterraine. Nous avons adopté pour une approche méthodique, mesurant deux paramètres clés : le RSSI (indicateur de puissance de signal reçus) et la somme des amplitudes au carré, tous deux des indicateurs de la force et de la qualité du signal reçu. L'utilisation d'une échelle logarithmique pour ces mesures est standard dans l'analyse des signaux sans fil, car elle permet de mieux gérer la large gamme de valeurs et de mettre en évidence les relations proportionnelles entre les mesures et la distance.




Figure 20 : RSSI et régression linéaire en fonction de distance en échelle logarithmique

1. Calibration du RSSI :

Le RSSI est une mesure fondamentale dans les systèmes de communication sans fil car il indique la puissance du signal reçu par le dispositif de réception. Lorsque le RSSI est représenté sur une échelle logarithmique en fonction de la distance, nous sommes en mesure de déduire comment la puissance du signal diminue avec l'éloignement entre l'émetteur et le récepteur. Cette décroissance, souvent linéaire dans un espace logarithmique, est confirmée par la régression linéaire appliquée que nous avons appliquée à vos données. La pente de cette régression linéaire donne un aperçu de l'atténuation du signal avec la distance, et est souvent utilisée pour modéliser la perte de chemin dans un environnement spécifique. Dans notre cas, la pente obtenue à partir des données RSSI indique un modèle d'atténuation qui peut être intégré dans des algorithmes de localisation pour compenser l'affaiblissement du signal dû à l'éloignement.




Figure 21 : Somme des amplitudes carrées et la régression linéaire en fonction de distance en échelle logarithmique

2. Analyse de la Somme des Amplitudes au Carré :

La somme des amplitudes au carré, en dB, est une autre métrique essentielle qui fournit des informations sur l'énergie totale du signal reçu sur l'ensemble des sous-porteuses d'un signal OFDM. En analysant cette somme sur une échelle logarithmique par rapport à la distance, nous avons pu observer comment les composantes énergétiques du signal varient en fonction de la distance parcourue dans l'environnement souterrain. Cette variation est cruciale pour comprendre non seulement la propagation du signal mais aussi pour évaluer la cohérence et la fiabilité des liens de communication dans des conditions variables.

Grâce à l'application d'une régression linéaire à ces données, nous pouvons déterminer une équation de calibration qui peut être utilisée pour estimer l'énergie du signal reçu à différentes distances. Cette équation est un outil précieux pour la calibration de notre système, car elle fournit un modèle de référence contre lequel les mesures réelles peuvent être comparées pour détecter des anomalies ou des

changements dans l'environnement de propagation.

Importance de la calibration dans la localisation précise : La calibration précise de ces deux paramètres est vitale pour les applications de localisation souterraine. En effet, la précision de la localisation dépend fortement de la capacité à estimer correctement la distance entre l'émetteur et le récepteur, ce qui est directement influencé par la qualité du signal reçu. Lorsque nous utilisons des données calibrées pour le RSSI et la somme des amplitudes au carré, nous augmentons significativement la précision de votre système de localisation. Ces données permettent de compenser les effets de l'atténuation du signal et d'autres phénomènes de propagation qui peuvent induire des erreurs dans la détermination de la position.

CHAPITRE 4

RÉSEAU DE NEURONES ARTIFICIELS :

4.1. Définition du réseau de neurone artificiels :

Un réseau de neurones artificiels (RNA) est une construction mathématique et informatique qui s'inspire du fonctionnement des réseaux neuronaux biologiques présents dans le cerveau humain. Chaque neurone dans un RNA est une unité de calcul qui reçoit des entrées, les traite et produit une sortie. Un RNA est typiquement structuré en plusieurs couches : une couche d'entrée, qui reçoit les signaux initiaux ; plusieurs couches cachées, qui traitent les signaux de manière intermédiaire ; et une couche de sortie, qui délivre le résultat final du réseau.

Les neurones sont connectés les uns aux autres par des liens appelés poids, lesquels sont ajustés au cours d'un processus d'apprentissage. Cette opération est souvent réalisée à travers un algorithme de rétropropagation du gradient, où l'erreur de la prédiction est utilisée pour mettre à jour les poids et minimiser l'erreur de sortie.

Chaque neurone applique une fonction d'activation à sa somme pondérée d'entrées pour introduire des non-linéarités dans le processus de l'information, ce qui permet au réseau de modéliser des relations complexes entre les données d'entrée et de sortie. Parmi les fonctions d'activation couramment utilisées, on trouve la fonction sigmoïde, la fonction tangente hyperbolique (tanh) et la fonction d'unité linéaire rectifiée (ReLU).

1. Architecture et Composition :

Un RNA est composé d'une série de couches. La couche d'entrée reçoit les données

brutes, semblable aux sens qui perçoivent les stimuli dans un organisme biologique. Les couches cachées, pouvant être une ou plusieurs, sont le cœur du réseau où le traitement complexe a lieu par l'intermédiaire de poids synaptiques et de fonctions d'activation. Quant à la couche de sortie, elle émet la prédiction ou la classification finale du réseau. Les couches cachées et de sortie sont composées de neurones ayant des poids et des biais ajustables, qui sont modifiés lors de l'apprentissage pour optimiser la performance du réseau.

2. Fonction d'Activation :

La fonction d'activation dans chaque neurone détermine si et comment les signaux sont transmis au travers du réseau. Ces fonctions peuvent être linéaires ou non-linéaires, et le choix de la fonction d'activation appropriée est crucial pour la capacité du réseau à résoudre des problèmes non linéaires et complexes.

3. Apprentissage et Ajustement des Poids :

Pendant l'apprentissage, le réseau ajuste ses poids et ses biais en réponse à l'erreur de sortie calculée par une fonction de coût ou de perte. La rétropropagation est une méthode où l'erreur est propagée du dernier au premier neurone, permettant au réseau de comprendre quelle contribution chaque neurone apporte à l'erreur finale. Les poids sont ensuite ajustés en fonction de cette contribution, généralement grâce à l'utilisation d'un algorithme d'optimisation tel que la descente de gradient ou ses variantes (comme Adam ou RMSprop), qui oriente les ajustements des poids dans une direction visant à réduire l'erreur.

4.2. Application du réseau de neurone artificiel :

L'application des réseaux de neurones artificiels (RNA) s'étend sur un large éventail de domaines allant de la reconnaissance d'image à la prédiction de séries temporelles, illustrant leur polyvalence et leur puissance comme outils de modélisation. Un RNA, modèle informatique inspiré de la structure neuronale du

cerveau humain, se compose d'un ensemble d'unités de traitement, les neurones, organisés en couches. Parmi ces couches, on retrouve généralement une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. Chaque neurone dans une couche est connecté à plusieurs neurones dans la couche suivante, et ces connexions sont pondérées par des coefficients qui ajustent la force et la signification du signal transmis.




Figure 22: Application de RNA

Au cœur du fonctionnement d'un RNA se trouve le processus d'apprentissage, où l'algorithme ajuste les poids synaptiques en réponse aux données d'entrée pour minimiser l'erreur de prédiction. Ce processus s'appuie sur des fonctions d'activation non linéaires, telles que la fonction sigmoïde, la fonction tangente hyperbolique ou la fonction ReLU (Rectified Linear Unit), pour introduire des complexités dans la manière dont le réseau traite les informations. Ces fonctions d'activation permettent

aux RNA de capturer et de modéliser des relations non linéaires entre les données d'entrée et de sortie, rendant possible l'apprentissage de tâches hautement complexes et variées.

L'apprentissage dans les RNA se déroule typiquement via un processus itératif connu sous le nom de rétropropagation. Durant cette phase, l'erreur de sortie du réseau est calculée et distribuée rétroactivement à travers les couches, permettant un ajustement fin des poids synaptiques. Cette méthode est souvent couplée à des techniques d'optimisation comme la descente de gradient stochastique ou ses variantes plus avancées telles que Adam ou RMSprop, qui cherchent à minimiser la fonction de coût, souvent représentée par la somme des carrés des erreurs ou l'entropie croisée.

Les RNA sont particulièrement utiles dans les domaines où les modèles traditionnels peinent à capturer la totalité des nuances présentes dans les données. En reconnaissance d'image, par exemple, ils sont capables d'identifier des motifs et des caractéristiques avec un niveau de précision qui dépasse souvent celui de la vision humaine. Dans le secteur financier, ils sont utilisés pour détecter des schémas complexes dans le comportement de trading ou pour identifier des transactions frauduleuses en apprenant des caractéristiques subtiles des données historiques. En médecine, les réseaux de neurones participent à la prédiction de maladies, à l'analyse d'images médicales, et à la personnalisation des traitements, exploitant leur capacité à modéliser des relations non linéaires et à découvrir des interactions entre symptômes et diagnostics qui ne sont pas immédiatement apparents. Le potentiel des RNA pour l'avenir est particulièrement prometteur dans le domaine de la localisation et de la navigation souterraines, où les conditions de signal sont extrêmement complexes en raison de la nature confinée et souvent imprévisible des environnements. Ici, les RNA peuvent être entraînés pour comprendre et interpréter les caractéristiques uniques des signaux de communication, telles que la perte de signal, la réflexion multipath et l'atténuation à travers différents milieux géologiques.

4.3. La Structure générale de RNA :

La structure générale d'un réseau de neurones artificiels (RNA) tire son inspiration du fonctionnement biologique des neurones présents dans le cerveau humain, tout en étant adaptée au traitement de l'information numérique. Un RNA conventionnel se compose de divers éléments interconnectés qui coopèrent afin d'exécuter des tâches complexes telles que la classification, la régression, la reconnaissance de motifs et les prédictions. Ci-dessous, nous proposons une description approfondie des éléments essentiels et de l'architecture globale d'un RNA :

1. Les Neurones:

- Chaque neurone artificiel constitue une entité de calcul recevant des entrées qu'il pondère, somme et soumet ensuite à une fonction d'activation en vue de produire une sortie. Chaque entrée se voit attribuer un poids représentant son importance relative, puis est agrégée et transmise aux couches suivantes. Le nombre de neurones dans cette couche correspond généralement au nombre de caractéristiques présentes dans les données d'entrée.

2. Les Couches de Neurones:

- Couche d'entrée : Constituée de neurones qui reçoivent les signaux du monde extérieur (les données d'entrée) et les transmettent aux couches suivantes. Le nombre de neurones dans cette couche correspond généralement au nombre de caractéristiques dans les données d'entrée.

- Couches cachées :

Les couches cachées, intercalées entre la couche d'entrée et la couche de sortie,

permettent au réseau de déceler des motifs complexes et des représentations abstraites des données. Le nombre de couches cachées ainsi que le nombre de neurones par couche peuvent varier et ont un impact crucial sur la capacité du réseau à appréhender des problèmes complexes.

- Couche de sortie regroupe les neurones responsables de l'émission du résultat du traitement du réseau. Pour une tâche de classification, cette couche peut compter un neurone par classe anticipée ; pour une régression, elle peut se limiter à un unique neurone reflétant la valeur continue prédite.

Un réseau de neurones artificiels (RNA) est un modèle computationnel basé sur les connexions entre des unités de traitement (neurones artificiels) qui s'inspirent du fonctionnement du cerveau humain. Le RNA est constitué de plusieurs couches de neurones interconnectées, chacune dotée de poids et de biais ajustés lors de la phase d'apprentissage.

L'apprentissage du RNA se fait en ajustant les poids et les biais du réseau de manière itérative à l'aide d'un algorithme d'optimisation tel que la descente de gradient. L'objectif est de minimiser une fonction de coût qui mesure la différence entre les sorties produites par le réseau et les sorties attendues pour les données d'entraînement.

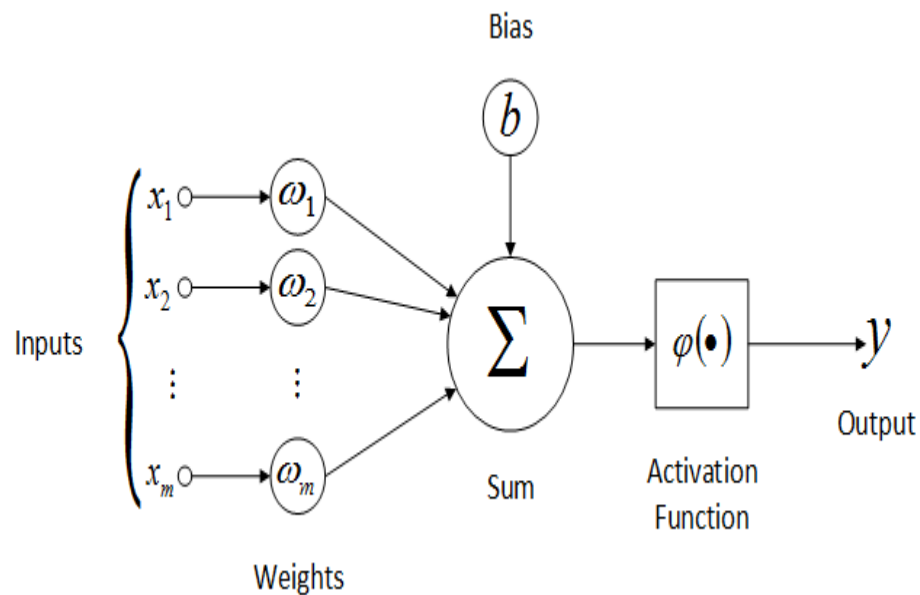


Figure 23: Presentation mathématique du RNA

$$y = \phi(\sum(x_i \cdot \omega_i) + b) \quad (8)$$

4.4. Fonctions d'activation pour RNA :

Les fonctions d'activation sont un élément fondamental dans les réseaux de neurones artificiels. Elles déterminent le seuil auquel un neurone est activé et transmet son signal. Leur caractère non linéaire confère aux RNA la capacité de résoudre des problèmes complexes, inaccessibles aux méthodes linéaires, et facilite l'introduction de propriétés telles que la dérivabilité, nécessaire au processus d'apprentissage par rétropropagation.

1. Fonction sigmoïde:
 - Définition et Usage:

La fonction sigmoïde, également appelée fonction logistique et comptant parmi les fonctions d'activation les plus anciennement employées, se distingue par son utilité dans les tâches de classification binaire. En effet, elle mappe les valeurs d'entrée dans une plage entre 0 et 1, offrant ainsi une interprétation probabilité.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$




Figure 24 : Fonction sigmoïde

- Avantages:
 - Bonne interprétation probabiliste.
 - Lisse et dérivable partout, ce qui est utile pour l'optimisation.
- Inconvénients:
 - Disparition du gradient: Pour des valeurs d'entrée très élevées ou très faibles, le gradient de la fonction sigmoïde devient très petit, ralentissant l'apprentissage.

➤ Non centrée sur zéro: Cela peut entraîner des problèmes de convergence pendant la formation du RNA.

2. Tangente Hyperbolique (Tanh) :

- Définition et Usage:

Tanh est une version normalisée de la fonction sigmoïde. Elle est souvent utilisée dans les couches cachées d'un réseau de neurones car elle mappe les valeurs entre -1 et 1, ce qui la rend plus efficace que la sigmoïde pour certaines applications.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (10)$$




Figure 25 : fonction de Tangente hyperbolique

- Avantages:
 - Centrée sur zéro, ce qui peut aider à améliorer l'efficacité de l'optimisation pendant l'apprentissage.
 - Dérivable et lisse, permettant un bon comportement pour la rétropropagation.
- Inconvénients:
 - Disparition du gradient: Comme la sigmoïde, elle souffre du problème de disparition du gradient, bien qu'elle soit généralement plus efficace que la sigmoïde en raison de sa plage de sortie centrée sur zéro.

3. ReLU (Rectified Linear Unit) :

- Définition et Usage:

ReLU, actuellement parmi les plus employées, notamment dans le contexte des réseaux de neurones profonds, se caractérise par sa capacité à transmettre directement les valeurs positives et à annuler les valeurs négatives. Cette particularité la rend hautement efficace pour de nombreuses configurations de réseaux.

$$f(x) = \max(0, x) \tag{11}$$




Figure 26 : fonction ReLU

- Avantages:
 - Réduction du problème de disparition du gradient (pour les valeurs positives).
 - Calculs plus rapides par rapport aux fonctions sigmoïde et tanh.
- Inconvénients:
 - Neurones morts: Pour les valeurs d'entrée négatives, le gradient devient nul, ce qui peut conduire à des neurones "morts" qui ne s'activent plus lors des itérations d'apprentissage.

3. Leaky ReLU:

- Définition et Usage:

C'est une variante de ReLU conçue pour pallier le problème de neurones morts.

Elle permet un petit gradient même pour les valeurs négatives.

$$f(x) = \max(0.01x, x) \quad (12)$$




Figure 27 : fonction Leaky ReLU

- Avantages:
 - Réduit le problème de neurones morts rencontré avec ReLU.
 - Préserve les avantages de ReLU en termes de vitesse de calcul.
- Inconvénients:
 - Le coefficient de "fuite" (ici 0.01) doit être choisi avec soin pour équilibrer l'apprentissage.

4. Softmax :

- Définition et Usage:

La fonction softmax est largement utilisée dans la couche de sortie des réseaux de neurones pour les tâches de classification multi classe. Elle convertit les scores (logits) en une distribution de probabilités.

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (13)$$

Pour $i=1, \dots, K$.




Figure 28 : fonction softmax

Le choix de la fonction d'activation dans un réseau de neurones dépend fortement du type de problème à résoudre et de la structure du réseau lui-même. Les fonctions d'activation non linéaires comme ReLU et ses variantes sont souvent privilégiées dans les réseaux de neurones profonds en raison de leur efficacité en termes de calcul et de leur capacité à atténuer le problème de disparition du gradient. Toutefois, pour des tâches spécifiques telles que la classification binaire ou multi classe, des fonctions comme la sigmoïde ou softmax sont plus appropriées.

Il est primordial de choisir une fonction d'activation appropriée pour chaque couche d'un RNA, en fonction de la nature des données et de la tâche à accomplir. Une fonction d'activation bien choisie peut grandement contribuer à améliorer les performances du RNA en permettant au modèle de détecter des motifs complexes dans les données.

4.5. Types de RNA :

Les réseaux de neurones artificiels (RNA) sont des outils puissants en apprentissage automatique, conçus pour imiter le fonctionnement du cerveau humain. Selon leur architecture et leur complexité, ils sont adaptés à diverses tâches, allant de simples classifications à des problèmes complexes de traitement de données. Les deux principales catégories de RNA sont les RNA à couche unique et les RNA à couches multiples.

- RNA à couche unique :

Les RNA à couche unique, aussi appelés perceptrons, sont les formes les plus basiques de RNA. Ils se composent d'une seule couche de neurones qui relie directement les entrées aux sorties. Cette simplicité les rend idéaux pour des tâches telles que la régression linéaire et la classification binaire. Par exemple, dans le domaine financier, ils peuvent être utilisés pour prédire si le prix d'une action augmentera ou diminuera, basé sur un ensemble de facteurs linéaires. Cependant, leur principal inconvénient réside dans leur incapacité à apprendre des relations non linéaires, ce qui limite leur utilisation dans des scénarios où les données d'entrée et de sortie présentent des modèles complexes et non linéaires.

- RNA à couches multiples :

Les RNA à couches multiples, aussi appelés réseaux de neurones profonds, sont composés de plusieurs couches de neurones, incluant des couches cachées entre les couches d'entrée et de sortie. Ces couches supplémentaires permettent au réseau d'apprendre et de modéliser des relations non linéaires complexes entre les données d'entrée et de sortie. Ils sont largement utilisés dans une variété d'applications, telles que la classification multi-classe, la reconnaissance d'images, la traduction automatique, et la prédiction de séries temporelles. Par exemple, dans le secteur de la santé, ils peuvent analyser des images médicales pour identifier des signes de

maladies, tandis que dans la reconnaissance vocale, ils permettent de transformer la parole en texte avec une précision remarquable.

En raison de leur capacité à apprendre des caractéristiques de haut niveau à partir des données, les RNA à couches multiples sont particulièrement efficaces dans le traitement des données complexes comme les images, les sons ou les textes. Cette capacité provient de la structure en couches qui permet au réseau de construire une représentation hiérarchique des données. Dans les premières couches, le réseau apprend à reconnaître des motifs simples (comme les bords dans une image), et dans les couches plus profondes, ces motifs sont combinés pour reconnaître des éléments plus complexes (comme des visages dans une image de reconnaissance faciale).




Figure 29: RNA à couches multiples

Les réseaux de neurones convolutifs (CNN), destinés principalement à la reconnaissance d'images, utilisent des filtres convolutifs pour extraire les caractéristiques des images. Ces filtres, constitués de matrices, parcourent l'image

pour calculer une carte d'activation, mettant ainsi en évidence les motifs présents dans l'image. Les CNN sont couramment employés pour la classification d'images ou la détection d'objets.




Figure 30: Exemple de réseaux du neurone convolutifs

Les réseaux de neurones récurrents (RNN), quant à eux, possèdent des connexions récurrentes leur permettant de traiter des séquences de données telles que du texte ou de la parole. Ces connexions récurrentes autorisent au modèle de conserver une mémoire à court terme des entrées précédentes, ce qui s'avère précieux pour la prédiction de séquences. Les RNN sont fréquemment utilisés dans des tâches de traitement du langage naturel telles que la traduction automatique ou la génération de texte.




Figure 31: réseaux de neurones récurrents (RNN)

4.6. Différentes méthodes d'apprentissage :

Il existe plusieurs méthodes d'apprentissage pour les réseaux de neurones. Le choix de la méthode dépend de la tâche à accomplir, de la nature des données et des ressources disponibles. Les méthodes d'apprentissage les plus courantes sont l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement.

- L'apprentissage supervisé est une méthode où le modèle apprend à partir d'un ensemble de données étiquetées. Chaque exemple dans les données d'entraînement comprend des entrées et les sorties correspondantes. Le modèle utilise ces exemples pour apprendre à prédire la sortie à partir de nouvelles entrées non vues auparavant.
- Dans l'apprentissage non supervisé, le modèle travaille sur des données non étiquetées. Son objectif est de découvrir des motifs ou des structures cachées sans aucune instruction spécifique sur ce qu'il doit trouver.

- L'apprentissage par renforcement est centré autour d'un agent qui apprend à prendre des décisions en interagissant avec un environnement. L'agent apprend à réaliser une série de tâches en cherchant à maximiser une récompense cumulative, souvent à travers des essais et erreurs.
- L'apprentissage semi-supervisé utilise à la fois des données étiquetées et non étiquetées pour améliorer l'apprentissage, souvent utilisé lorsque l'étiquetage des données est coûteux ou prend du temps. L'apprentissage par transfert, quant à lui, implique le transfert de connaissances acquises dans une tâche à une autre tâche connexe, permettant au modèle d'exploiter des apprentissages antérieurs et de s'adapter à de nouvelles tâches avec moins de données.

Il est vital de choisir la méthode d'apprentissage appropriée en fonction de la tâche à accomplir et des données disponibles pour obtenir les meilleures performances du modèle.

Pour notre projet, nous avons élaboré un modèle de réseau de neurones artificiels (RNA) en exploitant les capacités avancées de TensorFlow, un cadre essentiel pour l'apprentissage en profondeur. Notre modèle a été construit selon une architecture séquentielle, où les couches sont disposées successivement, chacune alimentant la suivante dans un ordre prédéfini. En parallèle, nous avons également conçu un modèle RNA en utilisant la bibliothèque Scikit-learn, réputée pour ses outils d'apprentissage automatique.

4.7. Perceptron Multi-Couches :

Dans notre recherche, nous avons utilisé MLP (Multilayer Perceptron) pour effectuer la régression. Les figures 23 représentent la structure abstraite d'un réseau MLP.




Figure 32: Structure abstraite d'un réseau MLP

Le MLP est un réseau de neurones feedforward avec au moins trois couches, à savoir l'entrée, une ou plusieurs couches cachées et la sortie. Chaque nœud dans chaque couche est connecté à tous les neurones des couches précédentes et suivantes, ce qui fait que MLP est un réseau de neurones entièrement connecté. Le processus d'apprentissage commence par l'attribution de valeurs aléatoires aux poids et aux biais. Ensuite, le réseau prend les entrées, multiplie les poids initiaux, ajoute les biais, calcule la somme et la passe à travers la fonction d'activation pour obtenir la sortie estimée et la comparer à la valeur réelle pour le calcul de l'erreur. L'erreur calculée est rétro propagée dans le réseau à l'aide de la descente de gradient pour minimiser l'erreur d'estimation en mettant à jour les poids et les biais à chaque itération.

Le MLP s'avère efficace pour la distinction de données non linéairement séparables, le rendant approprié pour la régression non linéaire. Dans notre expérience, nous avons essayé différentes configurations en ce qui concerne le nombre de couches cachées, le nombre de neurones dans chaque couche et la fonction d'activation de chaque couche. Plus de couches cachées ne conduisent pas à une meilleure précision, mais les performances d'un réseau compliqué sont

médiocres en ce qui concerne l'erreur de localisation.

Chaque neurone reçoit une entrée qui est une combinaison linéaire des sorties des neurones de la couche précédente. Pour un neurone i dans la couche l , la combinaison linéaire est donnée par :

$$z_i^{(l)} = \sum_j w_{ij}^{(l)} a_j^{(l-1)} + b_i^{(l)} \quad (14)$$

Où $a_j^{(l-1)}$ représente la sortie du neurone j dans la couche précédente ($l-1$), $w_{ij}^{(l)}$ est le poids associé à la connexion entre le neurone j et le neurone i , et $b_i^{(l)}$ est le biais du neurone i dans la couche l .

4.8. Tensor Flow et Scikit-learn:

TensorFlow est une bibliothèque logicielle pour l'apprentissage automatique qui permet aux chercheurs et aux développeurs de créer des modèles d'intelligence artificielle avancés, en particulier des réseaux de neurones. Son nom provient des opérations que ces réseaux effectuent sur des structures de données multidimensionnelles appelées tenseurs, qui sont des généralisations de matrices à des dimensions supérieures.

- Caractéristiques Principales :
 1. Flexibilité : TensorFlow offre une architecture flexible qui permet de déployer des calculs sur une ou plusieurs CPU ou GPU, sur des serveurs ou des appareils mobiles, en utilisant un seul API. Cette flexibilité est cruciale pour des applications nécessitant des performances de calcul élevées ou des déploiements sur des plateformes variées.
 2. Écosystème Riche : La bibliothèque est accompagnée d'un écosystème riche

comprenant TensorFlow Lite pour les applications mobiles, TensorFlow.js pour l'apprentissage automatique dans les navigateurs, et TensorFlow Extended (TFX) pour les pipelines de production d'apprentissage automatique à grande échelle.

3. Visualisation avec TensorBoard : TensorFlow est intégré avec TensorBoard, un outil de visualisation qui permet aux utilisateurs de visualiser graphiquement les graphes de calcul, les métriques de performance, et d'autres indicateurs clés, facilitant ainsi le débogage et l'optimisation des modèles.
4. Haute Performance : TensorFlow utilise la programmation parallèle pour effectuer des calculs efficaces, accélérant ainsi l'entraînement des modèles d'apprentissage profond et réduisant le temps nécessaire pour obtenir des résultats.

Scikit-learn, quant à lui, est une bibliothèque d'apprentissage automatique open source pour Python, réputée pour sa simplicité d'utilisation et ses performances tant dans la recherche académique que dans le développement commercial. Elle propose une large gamme d'algorithmes supervisés et non supervisés, notamment la classification, la régression, le clustering et la réduction de dimensionnalité.

Fonctionnalités de Scikit-learn :

- Diversité des algorithmes : Scikit-learn intègre de nombreux algorithmes de classification tels que les SVM, les forêts aléatoires, les k-plus proches voisins, et plus encore. Pour la régression, elle propose des régresseurs linéaires, des arbres de décision, et des réseaux de neurones, dont le MLPRegressor pour les modèles basés sur des perceptrons multicouches.
- Prétraitement des données : La bibliothèque fournit des outils complets pour le prétraitement des données, y compris la normalisation, la standardisation, et la gestion des valeurs manquantes, ce qui est crucial pour préparer les ensembles de données avant de les soumettre à des modèles d'apprentissage.

- Sélection et évaluation de modèle : Elle facilite la sélection de modèles et le réglage d'hyperparamètres grâce à des techniques telles que la recherche sur grille et la validation croisée. De plus, des métriques pour évaluer les performances des modèles sont facilement accessibles, permettant une analyse rigoureuse des résultats.
- Intégration et compatibilité : Scikit-learn s'intègre facilement avec d'autres bibliothèques Python telles que NumPy et SciPy pour les opérations mathématiques, et Matplotlib pour la visualisation. Elle est également compatible avec d'autres frameworks d'apprentissage profond comme TensorFlow, permettant une transition fluide entre les différents types de modélisation.
- Communauté et documentation : Avec une large communauté de contributeurs et une documentation exhaustive, Scikit-learn reste l'une des bibliothèques les plus accessibles pour ceux qui débutent en apprentissage automatique, tout en étant suffisamment robuste pour des applications complexes.

Dans le cadre de notre recherche, nous avons déployé Scikit-learn pour mettre en œuvre des modèles de régression par réseau de neurones, en utilisant notamment (MLPRegressor), et les avons comparés aux modèles générés par TensorFlow. L'objectif était d'évaluer la précision de localisation fournie par chacun dans un environnement souterrain complexe. Cette analyse comparative a révélé des insights cruciaux sur la performance de chaque modèle, mettant en lumière les avantages spécifiques de Scikit-learn et TensorFlow. En juxtaposant le MLP basé sur Scikit-learn avec celui basé sur TensorFlow, nous avons pu déterminer lequel des deux offrait la plus grande précision de localisation, exploitant ainsi les points forts de chaque framework pour améliorer nos capacités de localisation souterraine.

CHAPITRE 5

MÉTHODOLOGIE :

Dans ce chapitre, nous aborderons en détail la méthodologie employée lors de notre projet de recherche pour effectuer les mesures dans les environnements souterrains spécifiques des mines. Notre approche méthodologique se divise en plusieurs étapes clés, depuis la préparation initiale et la collecte des données jusqu'à leur traitement et leur analyse ultérieure.

Tout d'abord, nous exposerons la stratégie que nous avons mise en place pour la collecte des données sur le terrain, en mettant en évidence le déploiement stratégique des équipements dans les mines afin de capturer une gamme exhaustive de données environnementales et de signal. Cette section décrira également les protocoles de sécurité et les considérations logistiques que nous avons suivis pour garantir l'efficacité et la sécurité des opérations sur site.

Ensuite, nous détaillerons les méthodes utilisées pour le traitement des données recueillies, incluant les techniques de nettoyage et de préparation des données pour en assurer la qualité avant toute analyse. Cette partie inclura les processus de filtrage des données aberrantes, de normalisation des mesures et d'interpolation nécessaire pour pallier les données manquantes ou incomplètes. Nous aborderons aussi les méthodes statistiques et computationnelles adoptées pour analyser les données de manière à extraire des informations pertinentes qui sont cruciales pour la localisation précise dans les mines souterraines.

Enfin, nous discuterons de la préparation des données pour le processus d'apprentissage automatique, en expliquant comment elles ont été transformées en un format utilisable pour l'entraînement de nos modèles de réseaux de neurones. Cette étape est vitale pour garantir que les modèles puissent apprendre efficacement

des caractéristiques complexes des données environnementales souterraines. Cette phase inclut la sélection des caractéristiques, la réduction de dimensionnalité et la standardisation des données, qui sont toutes essentielles pour améliorer les performances des algorithmes de localisation que nous avons développés.

Ce chapitre vise à fournir une compréhension approfondie de chaque phase de notre méthodologie, reflétant l'attention méticuleuse aux détails qui est nécessaire pour mener à bien des recherches dans le domaine exigeant de la localisation souterraine.

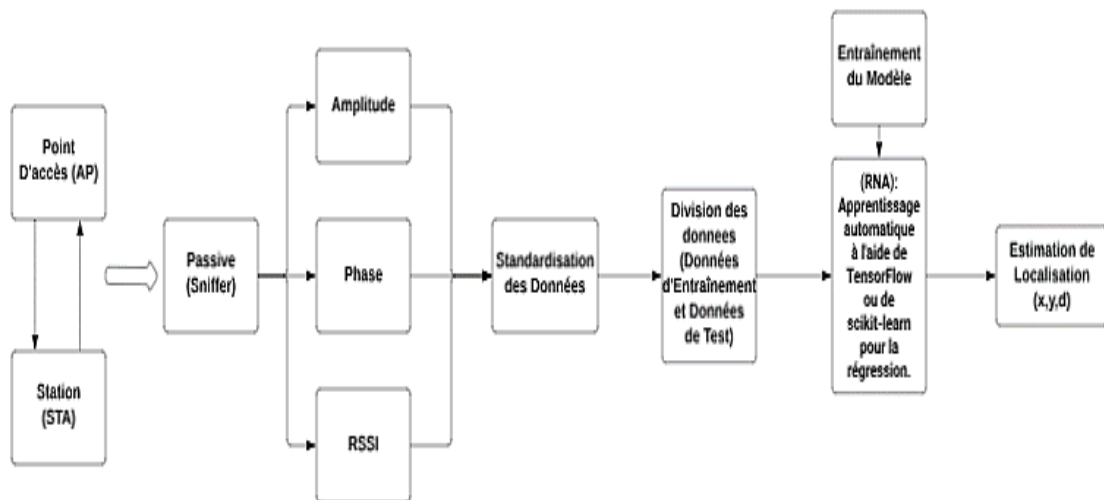


Figure 33 : Diagramme de méthodologie

Dans le cadre de notre projet de recherche dédié à la localisation souterraine, nous avons adopté une méthodologie de collecte de données et de modélisation basée sur l'utilisation de trois modules ESP32, chacun jouant un rôle distinct dans l'architecture de notre système. Le premier module a été configuré en tant que point d'accès (AP), et le second en tant que station (STA). Ces modules ont été déplacés systématiquement sur 303 points de mesure stratégiquement répartis dans un réseau

souterrain s'étendant jusqu'à 57 mètres, couvrant ainsi une vaste zone de test pour garantir la généralisation de notre modèle. Le troisième module ESP32, configuré en mode passif (Sniffer), était spécifiquement chargé de la collecte des informations de l'état du canal et des valeurs de l'indicateur de puissance du signal reçu (RSSI) pour la connexion entre l'AP et la STA. Cette configuration triangulaire a été essentielle pour capturer une gamme complète de données multidimensionnelles, facilitant une localisation précise dans l'environnement souterrain.

La précision de nos mesures a été renforcée par une configuration méticuleuse des paramètres du système. Nous avons choisi de fonctionner à une fréquence de 2,4 GHz avec une bande passante de 40 MHz, conformément aux spécifications du champ d'entraînement long (LLTF) du préambule Wi-Fi 802.11n. Cette sélection de fréquence et de bande passante a été faite en raison de leur efficacité prouvée dans la transmission de données à travers des environnements souterrains complexes, permettant une capture optimale des informations d'amplitude et de phase des sous-porteuses OFDM ainsi que des valeurs RSSI. Pour assurer l'intégrité des données, nous avons évité tout codage de canal susceptible d'altérer les données brutes. La puissance de transmission a été maintenue à 20 dBm avec un gain d'antenne de 3 dBi pour optimiser la réception à chaque point de mesure, où au moins 50 paquets de données ont été reçus pour garantir la consistance et la fiabilité des informations collectées.

Une fois la phase de collecte achevée, nous avons disposé d'une base de données considérable comprenant 45,163 enregistrements multi-dimensionnels. Chaque enregistrement encapsule une combinaison riche de l'amplitude et de la phase pour l'ensemble des sous-porteuses et des paquets, enrichie par les valeurs RSSI et les coordonnées spatiales précises des points de mesure. Ces données ont servi de fondation à notre modèle d'apprentissage automatique, spécifiquement conçu pour traiter et analyser la complexité des données CSI et RSSI.

Notre infrastructure de réseau de neurones multicouches a été développée en tirant

parti des capacités de deux plateformes d'apprentissage profond de pointe : TensorFlow et Scikit-learn. TensorFlow a été utilisé pour son environnement robuste permettant un entraînement approfondi des données, facilitant une standardisation efficace des données pour affiner les poids synaptiques et minimiser l'erreur de prédiction. En parallèle, Scikit-learn a permis une régression précise grâce à son MLP Regressor. Cette combinaison d'outils a optimisé notre modèle de réseau de neurones, permettant une amélioration significative de la précision de localisation pour les applications souterraines.

Le résultat de cet entraînement rigoureux a été la création d'un modèle hautement performant, capable d'estimer avec une précision remarquable la position des dispositifs dans un environnement souterrain complexe. Les paramètres du modèle, finement ajustés grâce aux algorithmes avancés de TensorFlow et Scikit-learn, ont abouti à une prédiction extrêmement précise des positions en deux dimensions. Ce succès démontre non seulement la viabilité de notre approche pour des applications de localisation souterraine mais également l'efficacité des techniques d'apprentissage profond lorsqu'elles sont appliquées de manière experte et ciblée.

En conclusion, notre méthodologie a permis d'envisager de nouvelles possibilités pour le déploiement de solutions de communication sans fil robustes dans le secteur minier, avec des implications directes sur la sécurité et la coordination des opérations minières. Cette avancée marque un jalon significatif pour les applications pratiques de localisation dans des environnements souterrains, ouvrant la voie à des recherches futures et à des améliorations continues dans ce domaine technique exigeant.

CHAPITRE 6

TEST ET RÉSULTAT :

6.1.Introduction :

Dans ce chapitre final, nous abordons l'aboutissement de notre projet de recherche innovant, à savoir l'analyse et la présentation des résultats obtenus grâce à notre méthodologie avancée de localisation souterraine. Axé sur l'exploitation stratégique de trois modules ESP32, ce projet a nécessité une collecte méticuleuse de données (CSI) ainsi que de l'indicateur de force du signal reçu (RSSI) dans un environnement souterrain complexe. Notre objectif principal consiste à élaborer un système apte à localiser de manière précise des objets ou des individus dans ce contexte, en tirant profit des techniques d'apprentissage automatique les plus sophistiquées. Ce chapitre met en exergue les données recueillies au fil de notre étude approfondie. Nous avons exploité la puissance des réseaux de neurones multicouches, élaborés à travers TensorFlow et Scikit-learn, afin de traiter et d'analyser ces données complexes. L'efficacité de ces modèles d'apprentissage automatique dans la prédiction précise de la localisation souterraine constitue un aspect clé de notre analyse.




Figure 34 : L'entrée et les sorties de notre réseau de neurone

Une analyse approfondie portant sur la précision, la fiabilité et les implications des résultats obtenus sera entamée. Cette démarche impliquera une évaluation minutieuse de la performance des modèles de machine learning et de leur application spécifique dans le domaine de la localisation souterraine. Par ailleurs, les répercussions pratiques de ces résultats seront examinées en détail, en mettant particulièrement l'accent sur leur capacité à améliorer la sécurité et l'efficacité dans des secteurs critiques tels que l'industrie minière.

6.2. Environnement universitaire (Polytechnique de Montréal) :

Le protocole d'essai de notre système, intégrant trois dispositifs ESP32, a été conçu pour évaluer la calibration et la performance de communication. Il comporte l'installation de deux dispositifs ESP32, agissant en tant que point d'accès et station de base, fixés à une distance déterminée et déplacés à travers vingt positions de mesure, distantes de 0,5 mètre (Figure 36) entre elles. Un dispositif ESP32 supplémentaire est dédié à l'interception des communications entre le point d'accès et la station de base. Ces tests ont été menés dans le couloir de la cafétéria de Polytechnique, avec les dispositifs de capture à une altitude de 1 mètre et les dispositifs AP et STA élevés à 1,5 mètre.




Figure 35 : Environnement universitaire (Polytechnique de Montréal)




Figure 36: Positions de esp passive et position de AP et STA

6.2.1. Base de données

La structure de notre base de données se présente comme suit :

1. Amplitude et Phase pour 64 Sous-Porteuses :
 - Notre collection inclut des données sur l'amplitude et la phase pour un total de 64 sous-porteuses par enregistrement. L'importance de ces informations réside dans leur capacité à révéler les nuances des signaux, facilitant une localisation d'une précision inégalée.
2. Valeurs RSSI (Received Signal Strength Indicator) :
 - Chaque enregistrement de la base de données est accompagné de sa valeur RSSI, un indicateur clé de la puissance du signal reçu. Ces valeurs sont indispensables

pour évaluer la qualité de la connexion entre l'appareil mobile et les points d'accès Wi-Fi, contribuant ainsi à l'efficacité de nos modèles de localisation.

3. Coordonnées X :

- Les coordonnées spatiales X, associées à chaque mesure, précisent l'emplacement de l'appareil au moment de la collecte. Cette donnée est fondamentale pour l'entraînement et l'évaluation de nos modèles, servant de référence pour mesurer la précision de nos prédictions.

Bien que notre base de données soit relativement modeste en termes de volume, avec seulement 3 923 enregistrements, chacun renfermant 130 variables significatives, elle représente une ressource inestimable. Elle nous permet de mener des analyses approfondies et de concevoir des modèles d'apprentissage automatique sophistiqués dans le but ultime d'atteindre une localisation précise, même dans des environnements souterrains.

En termes de gestion de la base de données, nous avons adopté une approche méthodique pour assurer une évaluation fiable de nos modèles. Les données, totalisant 3,923 enregistrements, ont été stratégiquement réparties en ensembles d'entraînement et de test. Ainsi, 80 % de la base, soit environ 3,138 enregistrements, ont été alloués à l'entraînement des modèles, leur permettant de saisir les relations complexes entre les amplitudes, phases, valeurs RSSI et coordonnées spatiales. Les 20 % restants, équivalents à 785 enregistrements, ont été conservés pour l'ensemble de test. Cet ensemble, isolé durant l'entraînement, sert à évaluer objectivement la performance de nos modèles, offrant une mesure indépendante de leur capacité à localiser précisément les appareils mobiles en situation réelle.

6.2.2. MLP en utilisant les deux algorithmes d'apprentissages automatique

Dans le cadre de notre enquête menée à l'École Polytechnique, nous avons adopté une

démarche méthodique, opérant une évaluation objective des performances de deux piliers éminents de l'apprentissage profond, à savoir TensorFlow et Scikit-learn, dans le contexte exigeant de la localisation précise en environnement souterrain. Cette étude a été orchestrée avec un souci de rigueur scientifique, mettant en exergue une concordance minutieuse des configurations des modèles de réseaux de neurones multicouches (MLP) sous ces deux paradigmes, dans le dessein de favoriser une comparaison circonstanciée et équitable.

Le modèle façonné avec TensorFlow s'est inscrit dans une architecture particulière, entamant par une strate dense de 150 neurones, se poursuivant avec une seconde couche de 200 neurones, pour finalement atteindre une troisième couche réduisant ce nombre à 50 neurones. Chacune de ces couches emploie la fonction d'activation ReLU pour introduire une non-linéarité efficace, tandis que la couche de sortie se compose de 2 neurones avec une activation linéaire, faute de spécification contraire.

De manière similaire, dans Scikit-learn, le modèle MLPRegressor a été ajusté pour correspondre exactement aux mêmes spécifications de couche et de nombre de neurones, en optant pour la fonction d'activation 'relu' et le solveur 'adam'. Les hyperparamètres additionnels, tels que le taux d'apprentissage et la tolérance pour la condition d'arrêt, ont été également standardisés afin d'assurer une comparaison équitable entre les modèles.

Cette uniformisation des structures de modèles nous a permis d'entreprendre une analyse comparative directe, visant à déterminer laquelle des deux plateformes d'apprentissage profond se montre la plus efficace dans la prédiction de localisations précises. En neutralisant les variables liées à la configuration des modèles, nous nous assurons que les variations de performance observées reflètent les qualités propres à chaque outil d'apprentissage profond, et non des différences dans l'architecture des modèles.

6.2.3. L'entraînement de notre deux modèles

Perte d'entraînement et de validation

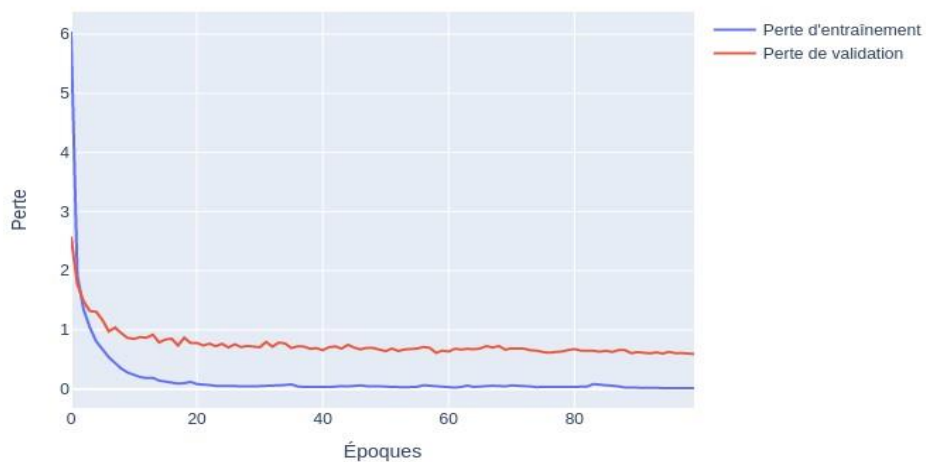


Figure 37: La perte d'apprentissage et de validation pour TF (Poly)

Perte d'entraînement et de validation




Figure 38: La perte d'apprentissage et de validation Scikit-learn (Poly)

L'examen des graphiques de perte d'entraînement et de validation pour TensorFlow et Scikit-learn montre que les deux cadres d'apprentissage automatique manifestent des courbes de performance similaires, démontrant une forte convergence entre la perte d'entraînement et de validation tout au long des itérations d'entraînement. Cela suggère une bonne généralisation des modèles sans indication évidente de surajustement ou de sous-ajustement. La perte diminue rapidement dans les premières époques, puis les deux modèles atteignent un plateau où peu de changements dans la perte sont observés, indiquant que les modèles ont probablement atteint leur performance optimale sur les données.

Cependant, il y a de légères différences entre les deux. La courbe de Scikit-learn montre une convergence un peu plus lisse entre les pertes d'entraînement et de validation comparativement à celle de TensorFlow, où la perte de validation reste légèrement supérieure à celle d'entraînement vers la fin des époques. Ces nuances pourraient indiquer une différence dans l'efficacité de l'entraînement ou dans la sensibilité aux paramètres du modèle entre les deux frameworks. En résumé, les deux outils sont compétents pour gérer les tâches d'apprentissage automatique, mais les choix entre TensorFlow et Scikit-learn pourraient être guidés par des préférences spécifiques en termes de facilité d'utilisation, de flexibilité de configuration, ou de performance dans des scénarios d'apprentissage particuliers.

6.2.4. Comparaison des resultats pour les deux modeles

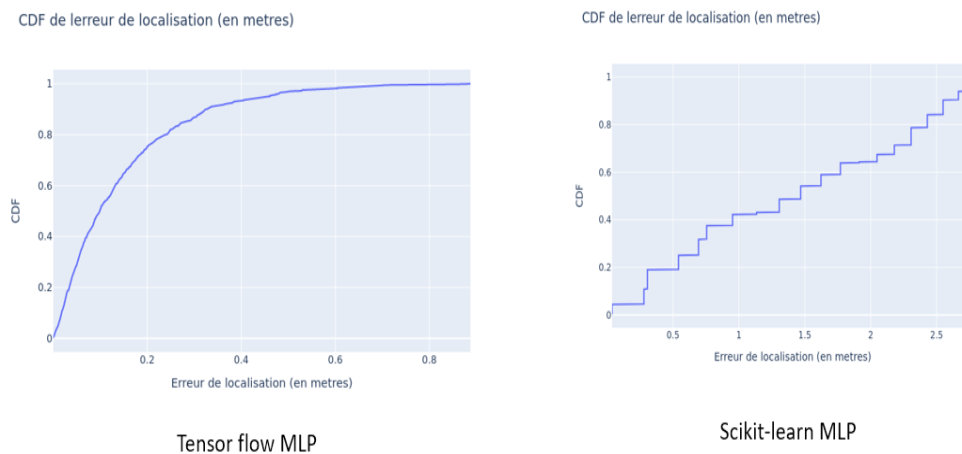


Figure 39: CDF des deux modèles

Les graphiques présentés illustrent la fonction de distribution cumulative (CDF) de l'erreur de localisation pour les modèles de réseau de neurones multicouches (MLP) développés avec TensorFlow et Scikit-learn.

Pour le modèle MLP conçu avec TensorFlow, la figure de gauche exhibe une courbe fluide et continue, escaladant rapidement, signifiant ainsi que la grande majorité des estimations de localisation s'inscrivent dans une marge d'erreur négligeable. Il est à noter, de manière spécifique, que l'erreur de localisation ne dépasse pas 0.8 mètre pour la quasi-totalité des estimations, témoignant ainsi d'une précision de localisation relativement élevée, avec une convergence rapide vers 1 dans la CDF, sous-entendant que la majorité des erreurs de localisation sont confinées dans une fourchette d'erreur minimale.

En revanche, pour le modèle MLP implémenté avec Scikit-learn, la figure de droite illustre une progression par paliers, laissant présager une dispersion des erreurs de localisation sur un intervalle plus large. L'erreur de localisation s'étend jusqu'à 2.5

mètres, dénotant ainsi que certaines estimations affichent une marge d'erreur notablement plus élevée par rapport au modèle TensorFlow. De surcroît, la pente moins abrupte de la courbe CDF suggère que les estimations de localisation sont moins focalisées autour de valeurs d'erreur minimales, ce qui pourrait être interprété comme une précision globalement moindre par rapport au modèle TensorFlow.

Précision de Localisation :

- Le modèle TensorFlow MLP atteint une précision de localisation impressionnante, évaluée à 96,286%, surpassant ainsi son homologue élaboré avec Scikit-learn qui se stabilise à une précision de 92,48%. Ce constat révèle la supériorité du modèle TensorFlow en termes de fiabilité pour la localisation précise.

1. Erreur absolue moyenne (Mean Absolute Error - MAE) :

- Avec une MAE de 0.146 m lors de la phase de test, le modèle TensorFlow MLP témoigne d'une capacité supérieure à prédire la localisation avec une précision remarquable, en contraste frappant avec le modèle Scikit-learn MLP qui affiche une MAE nettement plus élevée, atteignant 1,219 m.

2. Erreur Quadratique Moyenne Racine (Root Mean Squared Error - RMSE) :

- Le modèle TensorFlow MLP affiche un RMSE de 0.204 m, ce qui suggère que les erreurs de prédiction sont généralement faibles et peu nombreuses. En revanche, le modèle Scikit-learn MLP révèle un RMSE substantiellement plus élevé, se chiffrant à 1.5 mètres, traduisant ainsi une dispersion accrue dans les erreurs de prédiction.

La performance supérieure du modèle TensorFlow MLP en matière de précision de

localisation et d'erreur minimale dans toutes les catégories évaluées le désigne comme un choix optimal pour des applications de localisation souterraine précise. L'écart significatif entre les deux modèles, particulièrement en termes d'erreur maximale, souligne la robustesse du modèle TensorFlow dans des scénarios divers et potentiellement imprévisibles.

Fort de ces constats, nous sommes en mesure d'affirmer que notre système est désormais paré pour les essais en milieu souterrain. La performance établie du modèle TensorFlow MLP, en particulier, érige une assise solide pour des tests grandeur nature, où la précision et la fiabilité sont des impératifs. Ainsi, nous envisageons la phase de test en milieu souterrain avec confiance, dans l'attente de résultats prometteurs en termes de localisation précise et fiable.

6.3. Environnement Industrielle souterraine :

6.3.1. Base de données

Notre base de données constitue le pilier central de notre recherche, offrant une riche source d'informations pour la localisation précise des appareils mobiles en milieu souterrain. Elle est caractérisée par une diversité de données essentielles, chaque ensemble de mesures contribuant de manière significative à notre compréhension globale de l'environnement.

Plus précisément, notre base de données est constituée des éléments suivants :

1. Amplitude et Phase pour 64 Sous-Porteuses :

- Chaque paquet de données dans notre base de données comprend les mesures d'amplitude et de phase pour un total de 64 sous-porteuses. Cette information détaillée sur les sous-porteuses est cruciale pour capturer les variations subtiles dans les signaux, permettant ainsi une localisation plus précise.

2. Valeurs RSSI (Received Signal Strength Indicator) :

- Pour chaque paquet de données enregistré, nous avons inclus les valeurs RSSI correspondantes. Le RSSI représente la puissance du signal reçu et se révèle un indicateur essentiel de la force du signal entre l'appareil mobile et les points d'accès Wi-Fi. Ces données sont essentielles pour évaluer la qualité du signal et sont utilisées dans nos modèles de localisation.

3. Coordonnées X et Y :

- Chaque paquet de données s'adjoint également des coordonnées spatiales en X et en Y, qui définissent la position de l'appareil mobile au moment de la mesure. Ces informations sont révélatrices pour l'entraînement et la validation de nos modèles de localisation, car elles servent de repères tangibles pour évaluer la justesse de nos prédictions.

Dans son intégralité, notre base de données est une compilation minutieuse de 45 163 enregistrements, chacun contenant 131 informations pertinentes. Cette abondance de données nous confère les ressources nécessaires pour mener des analyses approfondies et entraîner des modèles d'apprentissage automatique sophistiqués, concourant ainsi à notre objectif de localisation précise en des environnements souterrains.

Quant à la répartition de notre base de données, nous avons suivi une approche rigoureuse pour garantir une évaluation précise de nos modèles. Notre base de données, composée de 45 163 enregistrements au total, a été divisée de manière stratégique en ensembles d'entraînement et de test.

Précisément, nous avons attribué 80 % de nos données à l'ensemble d'entraînement, ce qui équivaut à 36 130 enregistrements. Cet ensemble d'entraînement a été utilisé pour former nos modèles d'apprentissage automatique, leur permettant d'apprendre

les relations complexes entre les données d'amplitude, de phase, de RSSI et les coordonnées spatiales.

Les 20 % restants de la base de données, soit 9 033 enregistrements, ont été réservés à l'ensemble de test. Cet ensemble de test, préservé à l'écart au cours de la phase d'apprentissage, a été sollicité de manière exclusive pour évaluer la performance de nos modèles. Il se profile en tant que banc d'essai indépendant, pivot pour évaluer l'exactitude de la localisation des appareils mobiles.

Cette division en ensembles d'entraînement et de test assure la capacité de nos modèles à extrapoler au-delà des données d'entraînement, tout en maintenant leur performance en des situations concrètes. Elle octroie également une légitimité accrue à nos résultats et une fiabilité renforcée à nos évaluations, des piliers incontournables pour la réussite de notre entreprise de localisation en des environnements souterrains.

6.3.2. L'entraînement de notre deux modèles




Figure 40 : La perte d'apprentissage et de validation pour TF




Figure 41: La perte d'apprentissage et de validation Scikit-learn

Dans l'analyse de la phase d'apprentissage de nos modèles de localisation souterraine, nous avons discerné des tendances encourageantes au sein des courbes de perte (loss), tant pour l'entraînement que pour la validation, sur les deux plateformes de prédilection, à savoir TensorFlow et Scikit-learn.

Les graphiques illustrent clairement que, pour les deux modèles, la perte d'entraînement diminue rapidement au cours des premières époques, ce qui indique une capacité d'apprentissage efficace. De plus, la perte de validation suit étroitement la perte d'entraînement et stabilise à un niveau similaire, ce qui est un indicateur positif que nos modèles apprennent de manière généralisée à partir des données sans mémoriser les détails spécifiques de l'ensemble d'entraînement.

Cette convergence des courbes de perte d'entraînement et de validation suggère que les modèles ne souffrent ni de surajustement (overfitting) — où le modèle apprendrait les bruits ou les détails spécifiques de l'ensemble d'entraînement au détriment de la performance sur des données nouvelles — ni de sous-ajustement (underfitting) — où le modèle ne parviendrait pas à capturer la structure sous-jacente des données.

L'absence de ces deux problèmes est cruciale pour l'efficacité de la localisation souterraine, où les modèles doivent être capables de généraliser à partir de données complexes et souvent bruitées.

De plus, l'écart étroit et constant entre la perte d'entraînement et la perte de validation tout au long des époques avancées démontre que les modèles maintiennent leur performance lorsqu'ils sont confrontés à de nouvelles données, un attribut essentiel pour la validation de la robustesse du modèle dans des conditions réelles. En conclusion, ces tendances de perte indiquent un équilibre optimal entre la capacité d'apprentissage et la généralisation, confirmant l'adéquation des modèles pour notre application de localisation souterraine.

Les courbes de TensorFlow (figure 40) et scikit-learn (figure 41) montrent une convergence étroite entre la perte d'entraînement et de validation, suggérant une bonne généralisation sans surapprentissage significatif. Toutefois, la courbe de scikit-learn présente une légère sous-performance en termes de perte de validation par rapport à TensorFlow dans les époques ultérieures, ce qui peut signaler une légère différence dans la capacité de généralisation ou dans l'ajustement du modèle selon les spécificités des données ou des algorithmes utilisés.

6.3.3. MLP en utilisant les deux algorithmes d'apprentissages automatique

Dans notre étude, nous avons pris soin d'instaurer une méthodologie exigeante afin d'examiner de manière impartiale les performances de deux puissantes plateformes d'apprentissage profond, à savoir TensorFlow et Scikit-learn, dans le contexte délicat de la localisation souterraine. Afin de garantir une comparaison équitable, nous avons délibérément harmonisé la configuration des modèles de réseau de neurones multicouches (MLP) utilisés dans les deux environnements.

Pour le modèle développé avec TensorFlow, nous avons structuré le réseau comme suit : une couche initiale dense comptant 150 neurones, conséquente à laquelle succède une seconde couche, dotée de 200 neurones, pour finalement aboutir à une

troisième couche réduisant l'effectif neuronal à 50 unités. L'utilisation généralisée de la fonction d'activation ReLU confère une non-linéarité propice à l'efficacité du modèle. Par ailleurs, la couche de sortie est composée de 2 neurones, arborant une activation linéaire par défaut, à défaut de toute autre spécification explicite quant à la fonction d'activation.

Parallèlement, nous avons configuré le modèle MLPRegressor dans Scikit-learn avec les mêmes spécifications de couche et de neurones, en utilisant la fonction d'activation 'relu' et le solveur 'adam'. Les autres hyperparamètres, tels que le taux d'apprentissage initial et la tolérance pour la condition d'arrêt, ont été également alignés pour maintenir la cohérence entre les deux modèles.

Cette standardisation des architectures de modèles nous permet de mener une comparaison directe des résultats, en évaluant laquelle des deux plateformes offre une plus grande précision dans la prédiction de la localisation. En éliminant les variables de configuration du modèle, nous nous assurons que les différences observées dans la performance de localisation sont attribuables aux capacités intrinsèques des deux outils d'apprentissage profond et non à des disparités dans la structure des modèles.

- MLP en utilisant Tensor Flow :




Figure 42: Erreurs de localisation en termes de x, y et d en utilisant TF

La Figure 42 dépeint les erreurs de localisation dans les dimensions x, y, et la distance globale d pour notre modèle de localisation. Les graphiques illustrent la variabilité des erreurs à travers l'ensemble des 303 points de mesure dans notre environnement souterrain. L'erreur en x est restée relativement faible, indiquant une haute précision sur l'axe horizontal. En revanche, l'erreur en y montre une plus grande dispersion, suggérant une variabilité plus marquée sur l'axe vertical. Les erreurs en distance reflètent la combinaison des incertitudes en x et en y, et bien que certaines soient plus élevées, la majorité reste en dessous de 10 mètres, ce qui est prometteur pour l'application pratique de la localisation souterraine.




Figure 43: Comparaison des positions estimées et exactes en x et en y en utilisant TF

Cette figure compare les positions estimées par le modèle aux positions réelles, sur deux graphiques superposés pour les axes x et y. Les données montrent que les estimations de position sont proches des valeurs réelles avec un faible écart

systematique. Les variations sporadiques suggèrent des erreurs ponctuelles plutôt que des défaillances généralisées du modèle. Cela témoigne de la robustesse du modèle dans la prédiction des positions sous différentes conditions de mesure.

Positions estimées et exactes (en metres) en termes de x et de y

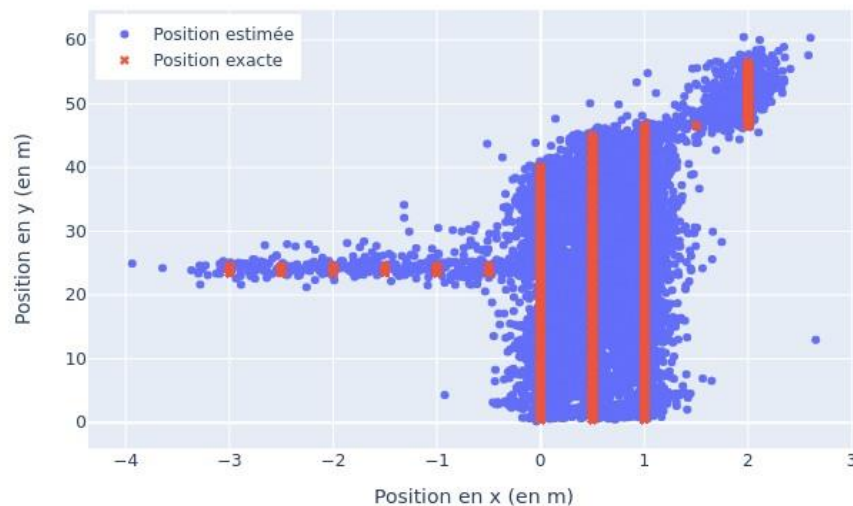


Figure 44: Visualisation des positions estimées et exactes dans le plan xy en utilisant TF

La Figure 44 offre une représentation visuelle des positions estimées versus les positions réelles pour l'intégralité des mesures. L'examen attentif des points bleus, correspondant aux estimations, juxtaposés aux croix rouges, représentant les positions réelles, dévoile une convergence souhaitable entre les deux ensembles. En effet, dans la plupart des cas, une proximité remarquable entre ces deux ensembles est observée. Cette observation notoire confirme la haute précision bidimensionnelle de notre modèle, une qualité inestimable pour la localisation précise dans des environnements souterrains exigeants.




Figure 45: Fonctions de Répartition Cumulée des Erreurs de Localisation en utilisant TF

La Figure 45 présente les fonctions de répartition cumulée pour les erreurs de localisation en x, en y et en distance. Ces courbes fournissent une perspective statistique sur la probabilité qu'une erreur soit inférieure à un seuil donné. Nous constatons que, pour les erreurs en x et en y, la plupart se concentrent dans les premiers mètres, renforçant ainsi la confiance en la précision du modèle, surtout pour des applications où de faibles erreurs sont critiques.

Mathématiquement, la CDF est définie comme suit pour une variable aléatoire continue X :

$$F(x) = P(X \leq x) \quad (15)$$

où $F(x)$ est la fonction de répartition cumulative de X et $P(X \leq x)$ est la probabilité

que la variable aléatoire X soit inférieure ou égale à x .

Notre analyse quantitative a révélé une précision de localisation exceptionnelle de 92.116% pour le modèle basé sur le Perceptron multicouche (MLP). En examinant plus en détail les métriques de performance, nous avons enregistré une erreur quadratique moyenne racine (RMSE) de 0.289 m pour l'axe x et de 1.817 m pour l'axe y, tandis que l'erreur quadratique moyenne racine pour la distance (d) était de 1.839 m. En ce qui concerne l'erreur absolue moyenne (MAE), les valeurs étaient respectivement de 0.175 m pour l'axe x, 0.952 m pour l'axe y, et 0.998 m pour la distance. Ces résultats non seulement attestent de la précision du modèle dans la prédiction des positions, mais également de sa fiabilité dans la gestion de données issues d'un cadre souterrain complexe. Ils mettent en lumière l'efficacité remarquable du MLP lorsqu'il est appliqué à la localisation de haute précision.

- **MLP en utilisant Scikit-learn:**

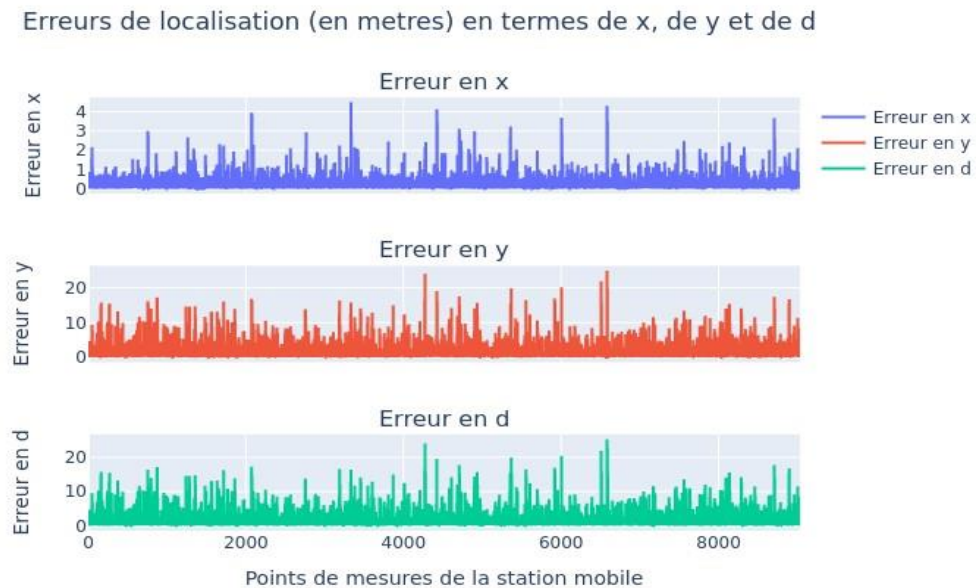


Figure 46 : Erreurs de localisation en termes de x, y et d en utilisant Sc-L

La Figure 46 affiche les erreurs de localisation pour les axes x, y et la distance totale d, calculées lors de l'utilisation du modèle MLP Régresseur de Scikit-learn. Les erreurs sont réparties sur les 303 points de mesure dans notre environnement souterrain. Il est notable que les erreurs en x restent généralement basses, tandis que les erreurs en y et en distance affichent une plus grande variabilité, indiquant des défis spécifiques dans la localisation verticale et la distance totale estimée.

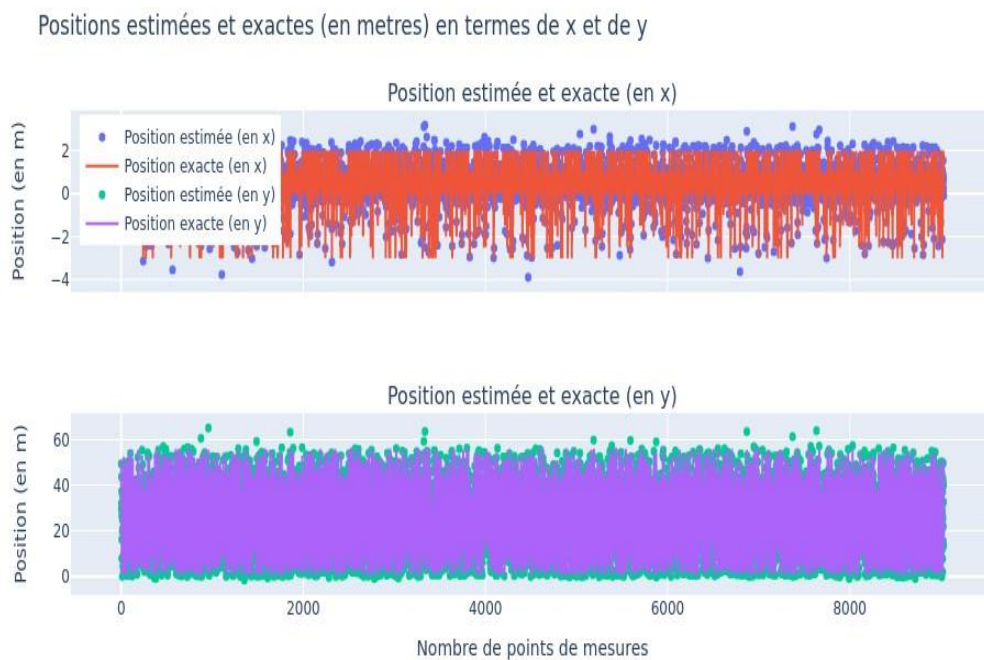


Figure 47 : Comparaison des positions estimées et exactes en x et en y en utilisant Sc-L

Cette figure montre une juxtaposition des positions estimées contre les positions réelles pour les axes x et y. Globalement, les estimations semblent globalement alignées avec les valeurs réelles, bien que certaines divergences soient visibles. Cela illustre l'exactitude globale du modèle dans l'estimation des positions, avec des erreurs

ponctuelles qui peuvent être attribuées à des anomalies spécifiques ou à des variations environnementales au sein des mesures souterraines.

Positions estimées et exactes (en metres) en termes de x et de y




Figure 48: Visualisation des positions estimées et exactes dans le plan xy en utilisant Sc-L

La Figure 48 nous donne une visualisation des positions estimées par rapport aux vraies positions sur le plan xy. Bien que la majorité des estimations soient proches des valeurs réelles, la dispersion des points autour de la ligne de position exacte suggère une marge d'erreur qu'il convient de prendre en considération lors de l'évaluation de la précision globale du modèle.




Figure 49: Fonctions de Répartition Cumulée des Erreurs de Localisation en utilisant Sc-L

La Figure 49 présente les fonctions de répartition cumulée pour les erreurs sur les axes x, y et la distance d. Ces courbes CDF démontrent la probabilité que l'erreur de localisation reste en dessous d'un certain seuil, offrant une perspective quantitative sur la distribution des erreurs et la fiabilité des estimations de localisation faites par le modèle.

Les performances du modèle Scikit-learn sont synthétisées par les statistiques suivantes : une précision de localisation de 86.8%, une erreur quadratique moyenne racine (RMSE) pour l'axe x de 0.37 m, pour l'axe y de 2.345 m, et pour la distance de 2.375 m. Les erreurs absolues moyennes (MAE) s'élèvent à 0.242 m pour l'axe x, 1.387 m

pour l'axe y, et 1.444 pour la distance. Ces chiffres, légèrement supérieurs à ceux obtenus avec TensorFlow, indiquent une certaine marge de progression pour améliorer la précision de localisation avec Scikit-learn. Néanmoins, ils reflètent une capacité robuste de prédiction dans un environnement souterrain avec ses propres défis inhérents.

6.3.4. Comparaison des performances des deux modèles

Lors de la comparaison des performances entre les modèles développés avec TensorFlow et Scikit-learn pour notre tâche de localisation souterraine, des différences notables émergent à partir de nos analyses détaillées. Le modèle TensorFlow a démontré une supériorité en termes de précision, atteignant un taux impressionnant de 92.116%, contre 86.8% pour le modèle Scikit-learn. Cette différence de plus de 5% est significative dans le domaine de la localisation précise, où chaque pourcentage compte.

En ce qui concerne l'erreur quadratique moyenne racine (RMSE), qui mesure la racine de la moyenne des carrés des erreurs, le modèle TensorFlow présente des valeurs plus faibles pour les axes x et y ainsi que pour la distance (d), avec des RMSE respectifs de 0.289 m, 1.817 m et 1.839 m. En comparaison, le modèle Scikit-learn affiche des RMSE de 0.37 m en x, 2.345 m en y et 2.375 m en d. Ces chiffres indiquent que le modèle TensorFlow est plus précis dans l'estimation de la position, avec des erreurs nettement moindres.

Quant à l'erreur absolue moyenne (MAE), qui est une mesure plus intuitive des erreurs moyennes, le modèle TensorFlow surpasse également Scikit-learn avec des erreurs de 0.175 m en x, 0.952 m en y et 0.998 m en d, contre 0.242 m en x, 1.387 m en y et 1.444 m en d pour Scikit-learn. Ces résultats sont cohérents avec le MSE, confirmant la tendance vers une plus grande précision de localisation avec TensorFlow.

Dans l'ensemble, bien que les deux modèles aient été conçus avec des architectures identiques pour permettre une comparaison équitable, il est évident que le modèle

TensorFlow a surpassé le modèle Scikit-learn dans notre contexte spécifique. Les raisons de cette différence pourraient être attribuées à des facteurs tels que l'efficacité des algorithmes d'optimisation internes, la gestion des calculs en parallèle, ou la manière dont chaque plateforme gère le surajustement et la généralisation à partir des données d'entraînement. En conclusion, pour notre projet de localisation souterraine, TensorFlow s'est avéré être la plateforme la plus précise, offrant des estimations de localisation plus fiables et moins erronées.

CHAPITRE 7

CONCLUSION :

Notre recherche s'est engagée dans une exploration minutieuse d'une exploration approfondie de la localisation souterraine, un défi technique complexe et d'une importance incontournable pour des applications telles que la sécurité minière et la navigation souterraine. À travers l'implémentation de technologies avancées et la mise en œuvre de techniques d'apprentissage automatique de pointe, nous avons contribué de manière significative à la compréhension et à l'amélioration de la localisation précise dans des environnements où les méthodes traditionnelles de localisation sont souvent inefficaces. Des dispositifs à faible coût tels que les ESP32 pour la localisation souterraine, en utilisant l'état du canal sans fil sur une distance allant jusqu'à 57 mètres. En tirant parti de ces dispositifs abordables, nous avons pu mettre en œuvre une approche économique tout en garantissant des performances fiables dans la localisation précise d'objets ou d'individus dans des environnements souterrains. Cette utilisation innovante des ESP32 souligne notre capacité à proposer des solutions efficaces et accessibles pour des applications critiques telles que la sécurité minière et la navigation souterraine.

En tirant parti de la synergie entre les modules ESP32 et les réseaux de neurones multicouches (MLP), nous avons développé un modèle capable d'interpréter avec précision les données CSI et RSSI pour une localisation fiable. L'architecture de notre modèle, appliquée à la fois sur TensorFlow et Scikit-learn, a été finement réglée pour capturer la complexité des signaux dans des conditions souterraines variées et imprévisibles.

Les résultats obtenus illustrent non seulement la viabilité de notre approche, mais

également la précision remarquable avec laquelle les modèles ont pu estimer les positions souterraines. Les performances de localisation du modèle TensorFlow ont été particulièrement notables, surpassant celles du modèle Scikit-learn avec une précision globale de plus de 92%. Les analyses détaillées des erreurs de localisation et des courbes de perte durant l'entraînement ont confirmé que nos modèles étaient bien ajustés, sans signes de surajustement ni de sous-ajustement.

Il est essentiel de reconnaître que, malgré notre succès, chaque projet de recherche comporte des limitations et des opportunités pour des travaux futurs. La poursuite de cette recherche pourrait explorer l'impact de différentes architectures de réseaux de neurones, l'intégration de techniques d'apprentissage non supervisées ou semi-supervisées et l'expansion vers des applications en temps réel.

En conclusion, cette thèse a non seulement avancé la frontière de la localisation souterraine, mais a également posé les jalons pour de futures explorations qui pourraient transformer la manière dont nous interagissons avec et naviguons dans des environnements souterrains. Notre recherche a démontré avec succès que, grâce à l'ingéniosité humaine et à l'innovation technologique, même les environnements les plus inaccessibles peuvent être rendus plus sûrs et plus accessibles.

RÉFÉRENCES

- [1] <https://mining.ca/resources/press-releases/economic-impacts-and-drivers-for-the-global-energy-transition-report-highlights-state-of-canadas-mining-industry/>
- [2] Thoen, B., Wielandt, S., and De Strycker, L. "*Fingerprinting Method for Acoustic Localization Using Low-Profile Microphone Arrays.*" 2018 International Conference on Indoor Positioning and Indoor Navigation, IEEE, 2018, pp. 1-7.
- [3] Leonardo, R., Barandas, M., and Gamboa, H. "*A Framework for Infrastructure-Free Indoor Localization Based on Pervasive Sound Analysis.*" IEEE Sensors Journal, vol. 18, no. 10, 2018, pp. 4136-4144.
- [4] Rishabh, I., Kimber, D., and Adcock, J. "*Indoor Localization Using Controlled Ambient Sounds.*" 2012 International Conference on Indoor Positioning and Indoor Navigation (IPIN), IEEE, November 2012, pp. 1-10.
- [5] Want, R., Hopper, A., Falcao, V., and Gibbons, J. "*The Active Badge Location System.*" ACM Transactions on Information Systems (TOIS), vol. 10, no. 1, 1992, pp. 91-102.
- [6] Vidal, J., and Lin, C. Y. "*Simple and Robust Localization System Using Ceiling Landmarks and Infrared Light.*" 2016 12th IEEE International Conference on Control and Automation (ICCA), IEEE, June 2016, pp. 583-587.
- [7] Wang, K., Song, T., Liang, T., Nirmalathas, A., Lim, C., Alameh, K., and Skafidas, E. "*A Dual-Infrared-Transmitter Optical Wireless Based Indoor User Localization System with High Accuracy.*" 2017 Optical Fiber Communications Conference and Exhibition (OFC), IEEE, March 2017, pp. 1-3.
- [8] Li, J., Guo, M., and Li, S. "*An Indoor Localization System by Fusing Smartphone Inertial Sensors and Bluetooth Low Energy Beacons.*" 2017 2nd International Conference on Frontiers of Sensors Technologies (ICFST), IEEE, April 2017, pp. 317-321.
- [9] Hou, X., Arslan, T., and Gu, J. "*Indoor Localization for Bluetooth Low Energy Using Wavelet and Smoothing Filter.*" Proc. 2017 International Conference on Localization and GNSS (ICL-GNSS), June 2017, pp. 1-6.
- [10] Dobrev, Y., Flores, S., and Vossiek, M. "*Multi-Modal Sensor Fusion for Indoor Mobile Robot Pose Estimation.*" Proceedings of IEEE/ION Position, Location and Navigation Symposium (PLANS) 2016, 2016.
- [11] Salamah, A. H., Tamazin, M., Sharkas, M. A., and Khedr, M. "*An Enhanced WiFi*

- Indoor Localization System Based on Machine Learning.*" 2016 International Conference on Indoor Positioning and Indoor Navigation (IPIN).
- [12] Hernandez, S. M., and Bulut, E. "*Scheduled Spatial Sensing against Adversarial WiFi Sensing.*" 2023 IEEE International Conference on Pervasive Computing and Communications (PerCom), IEEE, Atlanta, GA, USA, 2023, pp. 91-100, doi: 10.1109/PERCOM56429.2023.10099079.
- [13] Choi, H., Matsui, T., Misaki, S., Miyaji, A., Fujimoto, M., and Yasumoto, K. "*Simultaneous Crowd Estimation in Counting and Localization Using WiFi CSI.*" Proceedings of the International Conference on Indoor Positioning and Indoor Navigation (IPIN), November 2021, pp. 1-8.
- [14] Sanam, T. F., and Godrich, H. "*An Improved CSI Based Device Free Indoor Localization Using Machine Learning Based Classification Approach.*" 2018 26th European Signal Processing Conference (EUSIPCO), IEEE, September 2018, pp. 2390-2394.
- [15] Wang, X., Wang, X., and Mao, S. "*CiFi: Deep Convolutional Neural Networks for Indoor Localization with 5 GHz Wi-Fi.*" 2017 IEEE International Conference on Communications (ICC), IEEE, May 2017, pp. 1-6.
- [16] Tian, X., Zhu, S., Xiong, S., Jiang, B., Yang, Y., and Wang, X. "*Performance Analysis of Wi-Fi Indoor Localization with Channel State Information.*" IEEE Transactions on Mobile Computing, vol. 18, no. 8, 1 Aug. 2019, pp. 1870-1884, doi: 10.1109/TMC.2018.2868680.
- [17] Retscher, G. "*Indoor Navigation—User Requirements, State-of-the-Art and Developments for Smartphone Localization.*" Geomatics, vol. 3, no. 1, 2022, pp. 1-46, doi: 10.3390/geomatics3010001.
- [18] Samadani, S. M., Savaria, Y., and Nerguizian, C. "*Indoor Localization Using Channel State Information With Regression Artificial Neural Networks.*" 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring), IEEE, Antwerp, Belgium, 2020, pp. 1-4, doi: 10.1109/VTC2020-Spring48590.2020.9128759.
- [19] Halperin, D., Hu, W., Sheth, A., and Wetherall, D. "*Tool Release: Gathering 802.11n Traces with Channel State Information.*" ACM SIGCOMM Computer Communication Review, vol. 41, no. 1, 2011, p. 53.
- [20] Atif, Muhammad, Muralidharan, Shapna, Ko, Heedong, and Yoo, Byounghyun. "*Wi-ESP—A Tool for CSI-based Device-Free Wi-Fi Sensing (DFWS).*" Journal of Computational Design and Engineering, vol. 7, no. 5, Oct. 2020, pp. 644-656, <https://doi.org/10.1093/jcde/qwaa048>.
- [21] Hernandez, S. M. "*ESP32-CSI-Tool.*" GitHub, no date, <https://github.com/StevenMHernandez/ESP32-CSI-Tool>.

ANNEX A : EXEMPLE D'UN PAQUET CSI

```
CSI_DATA,C2:F4:59:75:71:79,[82 -96 4 0 0 0 0 0 0 0 0 -16 -24 -15 -24 -15 -25 -13  
-25 -12 -26 -11 -25 -12 -26 -10 -25 -11 -24 -7 -25 -5 -25 -5 -25 -5 -24 -5 -23 -6 -21 -8  
-21 -7 -20 -8 -21 -9 -20 -10 -20 -11 -20 -12 -20 -11 -21 -10 -22 -10 -22 -11 -22 0 0 -12  
-22 -13 -22 -12 -22 -13 -24 -13 -23 -13 -23 -14 -23 -13 -23 -13 -22 -12 -24 -10 -23 -10  
-22 -9 -21 -10 -21 -13 -20 -13 -19 -13 -21 -13 -19 -14 -17 -16 -17 -16 -17 -17 -16 -17  
-19 -16 -19 -17 -19 -17 -18 0 0 0 0 0 0 0 0 0 ]
```