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 la personne autrice 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'autrice ou 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

ÉVALUATION DE LA LOCALISATION DES RÉSEAUX NEURONAUX À L'AIDE DE RSSI ET CSI

Mémoire
présenté
comme exigence partielle
de la Maîtrise en ingénierie

Par
Hussam Zgheib

Mars 2026

© Hussam Zgheib, 2026

REMERCIEMENTS

Je tiens à exprimer ma profonde gratitude à mes directeurs de recherche, le Professeur Nahi Kandil et le Professeur Nadir Hakim, pour leur encadrement, leur disponibilité et leurs précieux conseils tout au long de ce travail. Leur expertise, leur rigueur scientifique et leur soutien constant ont été déterminants pour la réalisation de ce mémoire.

Je souhaite également remercier sincèrement ma famille, pour son soutien indéfectible, sa patience et ses encouragements tout au long de mon parcours académique.

Mes remerciements s'adressent aussi à Aurélien Seurier et Clément N. Zoleko, pour leur aide précieuse lors des campagnes de mesures réalisées dans la mine. Leur engagement, leur disponibilité et leur collaboration sur le terrain ont largement contribué à la réussite de ce travail expérimental.

Je remercie également les agents de sécurité, dont l'assistance a été essentielle pour le transport du matériel et pour garantir le bon déroulement des opérations dans un environnement exigeant. Leur professionnalisme et leur soutien ont permis de mener les mesures dans des conditions optimales de sécurité.

J'adresse enfin mes sincères remerciements à toutes celles et tous ceux que je n'ai pas explicitement mentionnés, mais qui m'ont soutenu de près ou de loin tout au long de ce parcours, notamment Nour et Mohamad, pour leur confiance et leurs encouragements.

Enfin, je présente mes excuses à mes proches, amis et collègues pour mes absences et mon manque de disponibilité durant cette période. Je les remercie sincèrement pour leur patience, leur compréhension et leur soutien.

À toutes et à tous, je vous remercie sincèrement.

Que Dieu nous protège et nous guide dans la réalisation de nos projets.

TABLE DES MATIÈRES

REMERCIEMENTS II
TABLE DES MATIÈRES III
LISTE DES FIGURES VI
LISTE DES TABLEAUX VIII
LISTE DES SIGLES ET DES ABRÉVIATIONS IX
LISTE DES SYMBOLES ET DES UNITÉS XI
RÉSUMÉ XII
1. INTRODUCTION 13
1.1 Problématiques 14
1.1.1 Effets du milieu souterrain confiné sur la propagation RF 14
1.1.2 Conséquences sur la problématique de localisation 16
1.1.3 Description et analyse de la problématique de propagation en milieu souterrain 17
1.2 Objectif 19
1.3 Hypothèse de recherche et cadre de l'étude 20
1.4 Structure du mémoire 22
2. REVUE DE LA LITTÉRATURE 23
2.1 Localisation dans les environnements sans GPS 24
2.1.1 Localisation sans fil à faible consommation énergétique 25
2.1.2 Localisation basée sur une infrastructure radio existante 26
2.1.3 Techniques de localisation basées sur le signal 27
2.1.4 Apprentissage automatique et apprentissage profond pour la localisation 28
2.2 Les Perceptrons Multicouches (MLP) 32
2.2.1 Principe général du MLP 32
2.2.2 Formulation mathématique 33
2.2.3 Fonction de coût et optimisation 34
2.2.4 Capacité d'approximation 35
2.2.5 Complexité paramétrique et limites du MLP 35
2.2.6 Application au fingerprinting/localisation CSI 35

2.3 Les Réseaux Neuronaux Entièrement Convolutionnels (FCNN) 36
2.3.1 Principe général du FCNN 36
2.3.2 Opération de convolution 37
2.3.3 Préservation de la structure spatiale 37
2.3.4 Application au fingerprinting CSI 38
2.3.5 Avantages et limites du FCNN en environnement minier 38
2.4 Réseau à Mémoire à Court Terme Longue (LSTM) 39
2.4.1 Principe général des LSTM 39
2.4.2 Structure interne d'une cellule LSTM 40
2.4.3 Application à la localisation basée sur RSSI et CSI 41
2.4.4 Avantages et limites du LSTM en environnement minier 42
2.4.5 Principes de généralisation des réseaux 42
2.5 Apprentissage profond supervisé pour la localisation en environnements miniers souterrains 43
2.6 Défis liés à l'application de l'apprentissage profond à la localisation 44
2.6.1 Contraintes liées à la collecte de données 45
2.6.2 Variabilité environnementale et effets de trajets multiples 46
2.6.3 Surapprentissage et généralisation 47
2.6.4 Complexité des modèles et contraintes matérielles 48
2.6.5 Effet d'évanouissement et échantillonnage spatial 49
2.6.6 Erreurs d'étiquetage et précision de la vérité terrain 49
2.7 Conclusion 50
3. MÉTHODOLOGIE 52
3.1 Dispositif expérimental et configuration matérielle 53
3.1.1 Configuration de mesure (émetteur–récepteur) 55
3.1.2 Système de positionnement basé sur des rails linéaires 55
3.2 Jeu de données initial (Section A) – Données de référence 56
3.3 Nouveau jeu de données (Section B) 59
3.4 Données, structure des échantillons et métadonnées 64
3.5 Stratégie d'évaluation et analyse de la généralisation 67
3.6 Modèles et architectures 70

3.6.1 Architecture FCNN (*Fully Convolutional Neural Network*) 71
3.6.2 Architecture MLP (*Perceptron multicouche*)..... 74
3.6.3 Architecture LSTM (*Long Short-Term Memory*) 76
3.7 Métriques de performance pour l'évaluation des modèles 78
3.7.1 Erreur quadratique moyenne racine (RMSE) 79
3.7.2 Erreur absolue moyenne (MAE) 80
3.7.3 Coefficient de détermination (R^2) 81
3.7.4 Fonction de répartition cumulative (CDF) des erreurs..... 82
3.8 Conclusion 83
4. RESULTATS 85
4.1 Évaluation selon les métriques RMSE, MAE et R^2..... 86
4.2 Analyse de la CDF des erreurs de localisation 88
4.2.1 Modèle MLP 88
4.2.2 Modèle LSTM 90
4.2.3 Modèle FCNN..... 92
4.3 Synthèse comparative des performances basée sur les CDF..... 95
4.4 Évaluation du meilleur modèle sur les nouveaux jeux de données 96
4.4.1 Évaluation quantitative des performances 97
4.4.2 Analyse de l'erreur de localisation et de la fonction de répartition cumulative 99
4.4.3 Analyse de la convergence des pertes d'entraînement et de validation 101
4.5 Discussion..... 103
4.6 Agrégation des données CSI avant l'apprentissage 107
4.7 Agrégation des prédictions après inférence..... 108
4.8 Conclusion 109
CONCLUSION.....111
ANNEXE A – EXEMPLE D'UN PAQUET CSI.....114
APPENDICE A – LISTE DES PUBLICATIONS.....115
LISTE DE RÉFÉRENCES 116

LISTE DES FIGURES

Figure 1 Photographie d'une Mine d'or souterrainne. 13
Figure 2 Phénomènes de propagations rencontrés dans le canal. 16
Figure 3 Topologie typique d'une mine 18
Figure 4 Trilatération basée sur satellite dans le GPS..... 24
Figure 5 Catégories de techniques d'apprentissage automatique dans la localisation sans fil. 29
Figure 6 Schéma de fonctionnement d'un système de localisation par apprentissage 32
Figure 7 Architecture du réseau de neurones MLP 33
Figure 8 Architecture du réseau de neurones FCNN..... 36
Figure 9 Architecture du réseau de neurones LSTM 40
Figure 10 Architecture du système d'acquisition de mesures Wi-Fi : Raspberry Pi et modules ESP (STA/AP) 55
Figure 11 Système de positionnement à rails linéaires et positions du point (bleu) et sous-points (vert) de mesure. 56
Figure 12 Installation du système de mesure dans un milieu souterrain réel..... 57
Figure 13 Distribution spatiale des points de mesure uniques (X, Y) le long du tunnel souterrain de la mine. 59
Figure 14 Architecture fonctionnelle de l'acquisition des données de localisation ... 61
Figure 15 Installation du système de mesure dans un milieu souterrain réel. 63
Figure 16 Distribution spatiale des points de mesure dans le tunnel courbe (LOS : bleu, NLOS : rouge) 64
Figure 17 Chaîne de prétraitement des données avant l'apprentissage automatique 65
Figure 18 Visualisation des sous-porteuses du signal CSI 67
Figure 19 Schéma comparatif des approches d'agrégation des données et des prédictions pour la localisation basée sur CSI. 69
Figure 20 Architecture des réseaux neuronaux pour la localisation..... 71
Figure 21 Architecture du réseau neuronal FCNN optimisé proposé..... 73
Figure 22 Localisation CDF des erreurs de localisation pour le modèle MLP 90

Figure 23 Localisation CDF des erreurs de localisation pour le modèle LSTM..... 92
Figure 24 Localisation CDF des erreurs de localisation pour le modèle FCNN 94
Figure 25 CDF de l'erreur de distance de localisation pour le modèle FCNN sur le nouveau jeu de données..... 101
Figure 26 Évolution des pertes d'entraînement et de validation du modèle FCNN. 103

LISTE DES TABLEAUX

Tableau 1 Comparaison des performances du modèle FCNN selon différentes configurations architecturales des couches cachées..... 72
Tableau 2 Comparaison des performances (RMSE & MAE, en mètres) des modèles FCNN, MLP et LSTM pour la prédiction des coordonnées X/Y. 87
Tableau 3 Performances du modèle FCNN sur les nouveaux jeux de données. 98
Tableau 4 Comparaison des performances de localisation avec l'état de l'art..... 106
Tableau 5 Performances de localisation obtenues avec les stratégies d'agrégation des échantillons CSI avant l'apprentissage 107
Tableau 6 Performances de localisation obtenues avant les stratégies d'agrégation des prédictions après inférence 108

LISTE DES SIGLES ET DES ABRÉVIATIONS

AOA — *Angle of Arrival :* estimation de la direction d'arrivée d'un signal.

CSI — Channel State Information : information décrivant l'état du canal radio (amplitude et phase).

DL — *Deep Learning :* sous-domaine du ML basé sur des réseaux neuronaux profonds.

ESP32 — Microcontrôleur avec Wi-Fi et Bluetooth intégré utilisé dans les systèmes embarqués.

FCNN — *Fully Connected Neural Network* : architecture neuronale où chaque neurone est connecté à tous ceux de la couche suivante.

GPS — *Global Positioning System* : système de positionnement par satellites.

KNN — *K-Nearest Neighbors :* algorithme basé sur les voisins les plus proches.

LOS — *Line of Sight :* propagation directe sans obstacle.

LSTM — *Long Short-Term Memory :* réseau neuronal récurrent capable d'apprendre des dépendances temporelles longues.

MAE — *Mean Absolute Error :* erreur absolue moyenne.

ML — *Machine Learning :* techniques d'apprentissage automatique à partir de données.

MLP — *Multi-Layer Perceptron :* réseau de neurones entièrement connecté utilisé pour modéliser des relations non linéaires.

NLOS — *Non-Line of Sight :* propagation indirecte avec obstacles.

R^2 — *Coefficient de détermination :* proportion de variance expliquée par le modèle.

RMSE — *Root Mean Square Error :* mesure quadratique moyenne de l'erreur.

RSSI — *Received Signal Strength Indicator :* mesure de la puissance du signal reçu.

SVM — *Support Vector Machine :* méthode d'apprentissage supervisé basée sur un hyperplan optimal.

TOF — *Time of Flight :* estimation de la distance basée sur le temps de propagation.

UWB — *Ultra-Wideband :* technologie radio large bande utilisée pour la localisation précise.

Wi-Fi — *Wireless Fidelity :* technologie de communication sans fil basée sur IEEE 802.11.

ZigBee — Protocole radio basse consommation basé sur IEEE 802.15.4.

LISTE DES SYMBOLES ET DES UNITÉS

(DB)V/m — Décibel-volt par mètre : unité logarithmique du champ électrique.

DB — Décibel : unité logarithmique utilisée pour exprimer un rapport de puissance ou de niveau.

GHz — Gigahertz : unité de fréquence équivalente à 10^{9} Hz.

MA — Milliampère : unité de courant électrique équivalente à 10^{-3} ampère.

MHz — Megahertz : unité de fréquence équivalente à 10^{6} Hz.

λ — Lambda : longueur d’onde exprimée en mètre.

RÉSUMÉ

La localisation en environnements souterrains, notamment en milieu minier, constitue un défi majeur en raison de l'absence de GPS et des conditions environnementales sévères qui perturbent la propagation des signaux sans fil. Dans ce contexte, les méthodes de localisation basées sur les mesures Wi-Fi représentent une alternative prometteuse.

Ce travail évalue les performances de trois architectures d'apprentissage profond — FCNN, MLP et LSTM — pour la localisation bidimensionnelle (X, Y) dans un tunnel minier souterrain. Les modèles exploitent des caractéristiques issues des signaux Wi-Fi, en particulier le RSSI et le CSI, collectées en conditions de visibilité directe (LOS) et de non-visibilité directe (NLOS). Un premier jeu de données, acquis dans une mine souterraine réelle, est utilisé pour l'entraînement et l'évaluation des modèles.

Les résultats montrent que le FCNN surpasse systématiquement les architectures MLP et LSTM, avec les plus faibles erreurs de localisation (RMSE et MAE) et les meilleurs coefficients de détermination (R^2). Cette performance met en évidence sa capacité à modéliser efficacement la relation complexe entre les caractéristiques des signaux sans fil et la position spatiale en environnement souterrain.

La robustesse du modèle est ensuite évaluée à l'aide d'un second jeu de données, collecté dans un corridor plus complexe de la même mine et dominé par des conditions NLOS. Sans réentraînement, le FCNN conserve une précision comparable, avec des valeurs de R^2 élevées et des erreurs acceptables, démontrant une bonne capacité de généralisation.

Dans l'ensemble, cette étude confirme que le FCNN constitue une solution robuste et fiable pour la localisation en environnements souterrains sans GPS, avec un fort potentiel pour des applications minières réelles telles que la sécurité, la navigation autonome et les systèmes de surveillance intelligents.

1. INTRODUCTION

La localisation — définie comme le processus visant à déterminer la position d'un objet ou d'une personne — joue un rôle essentiel dans un large éventail de systèmes modernes, notamment la navigation, les véhicules autonomes, la robotique et la gestion des situations d'urgence. Dans les environnements extérieurs, les technologies du Système de Positionnement Global (GPS) sont largement utilisées et offrent généralement une grande précision [1]. Cependant, dans les environnements où le GPS est inutilisable, comme les tunnels miniers souterrains, les signaux satellites sont totalement obstrués par les couches de roche et de sol, rendant les solutions traditionnelles basées sur les satellites inapplicables [2].

L'exploitation minière souterraine constitue l'un des environnements les plus contraignants pour la localisation. Ces milieux, tel qu'illustré à la figure 1, présentent des conditions telles que la faible visibilité, la poussière, l'humidité et des géométries irrégulières, qui compliquent aussi bien les solutions de suivi manuelles qu'automatisées. Un positionnement précis dans de tels environnements est essentiel pour assurer la sécurité des travailleurs, optimiser l'extraction des ressources, améliorer la gestion des équipements et faciliter la prise de décision en temps réel lors des situations d'urgence [3].



Figure 1
Photographie d'une Mine d'or souterrainne.

Les limites des systèmes conventionnels ont encouragé l'exploration de techniques de localisation alternatives basées sur les signaux de communication sans fil. Parmi celles-ci, deux métriques importantes se distinguent :

- Le *Received Signal Strength Indicator* (RSSI), qui estime la distance en fonction de l'atténuation du signal [4]
- Le *Channel State Information* (CSI), qui fournit une description plus détaillée de la propagation du signal à travers les multiples trajets [5].

Ces méthodes peuvent fonctionner à l'aide de matériel Wi-Fi largement disponible (par exemple, les modules ESP32) et sont généralement plus économiques que les systèmes de positionnement propriétaires. Par ailleurs, le développement des modèles d'apprentissage automatique et d'apprentissage profond a permis des améliorations significatives dans la localisation basée sur les signaux.

Des modèles tels que les perceptrons multicouches (MLP), les réseaux neuronaux convolutionnels (FCNN) et les réseaux de neurones à mémoire à court et long terme (LSTM) ont démontré des capacités robustes pour prédire la position des utilisateurs à partir de données bruitées ou non linéaires, même dans des environnements intérieurs complexes.

1.1 Problématiques

1.1.1 Effets du milieu souterrain confiné sur la propagation RF

L'absence de signaux GPS dans les environnements miniers souterrains rend impossible l'utilisation des systèmes de positionnement conventionnels. Les solutions alternatives actuellement déployées, allant du suivi manuel aux infrastructures technologiques lourdes, demeurent soit peu fiables dans des galeries étroites et riches en structures métalliques, soit trop coûteuses pour être déployées à grande échelle dans un réseau minier en expansion. Cette limitation complique le suivi précis des travailleurs et accroît les risques opérationnels ainsi que les délais d'intervention en situation d'urgence.

Dans ce contexte, les techniques de localisation fondées sur les signaux Wi-Fi, constituent une alternative plus flexible et économiquement viable. Toutefois, leur efficacité dépend directement du comportement du canal radio dans un environnement souterrain, où la propagation des ondes électromagnétiques est fortement influencée par la géométrie confinée des tunnels, la rugosité des parois, la présence de structures métalliques ainsi que les obstacles fixes ou mobiles.

Un canal de propagation (ou canal radio) désigne l'environnement physique à travers lequel une onde électromagnétique se propage entre un émetteur et un récepteur. On appelle chemin ou trajet l'itinéraire suivi par l'onde dans ce canal. Selon les interactions avec l'environnement, chaque trajet subit différents phénomènes physiques qui modifient le signal durant sa transmission, comme illustré à la Figure 2 :

- L'atténuation : perte progressive de puissance du signal due à la distance, aux matériaux environnants et à la topologie du tunnel ;
- La réflexion : rebond du signal sur des surfaces électriquement lisses ;
- La diffraction : contournement du signal autour des obstacles ;
- La diffusion (*scattering*) : dispersion de l'énergie due aux irrégularités des surfaces ;
- Le délai de propagation : temps nécessaire au signal pour parcourir un trajet donné.

La combinaison de ces phénomènes engendre une propagation multi-trajets, dans laquelle plusieurs copies du même signal atteignent le récepteur par différents chemins, avec des amplitudes, phases et délais distincts. Cette superposition provoque des interférences constructives et destructives qui modifient continuellement les caractéristiques du signal reçu. En conséquence, le canal radio en environnement minier souterrain devient fortement variable dans l'espace et dans

le temps, et son comportement dépend étroitement de la géométrie du tunnel, des matériaux environnants ainsi que de la présence d'obstacles.

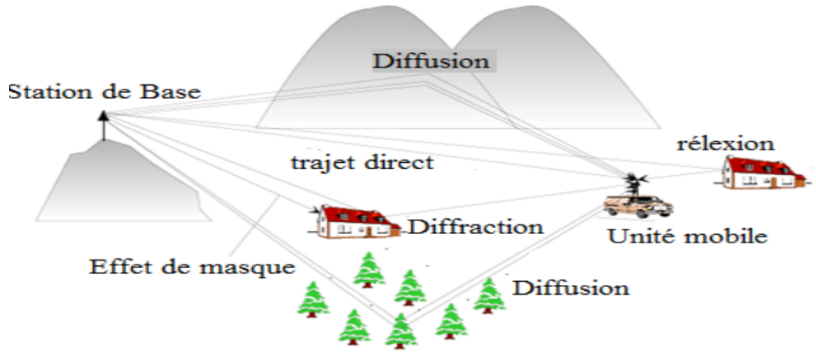

Figure 2
Phénomènes de propagations rencontrés dans le canal.

1.1.2 Conséquences sur la problématique de localisation

Cette forte variabilité du canal radio constitue le principal défi scientifique de la localisation en environnement minier souterrain. En effet, les effets de propagation multi-trajets rendent la relation entre les signatures radio mesurées et la position réelle fortement non linéaire, instable et ambiguë. Cette complexité compromet les hypothèses de stabilité et de continuité sur lesquelles reposent de nombreuses approches classiques de localisation.

Dans le cas du RSSI, cette difficulté est particulièrement critique, car cette métrique repose uniquement sur la puissance globale du signal reçu. Or, en environnement multi-trajets, différentes positions peuvent produire des niveaux de puissance similaires, tandis qu'une même position peut générer des valeurs différentes selon les conditions locales de propagation. Cette ambiguïté réduit fortement la capacité du RSSI à discriminer correctement les positions et limite la précision des modèles basés uniquement sur cette métrique.

Le CSI fournit une représentation plus détaillée du canal radio en intégrant des informations d'amplitude et de phase sur plusieurs sous-porteuses, ce qui permet de capturer plus finement les effets de propagation. Cette richesse informationnelle

s’accompagne d’une forte dimensionnalité et d’une sensibilité accrue aux variations environnementales, rendant son traitement plus complexe et exigeant des modèles capables d’extraire efficacement les caractéristiques pertinentes.

Le problème central ne réside donc pas uniquement dans l’absence des signaux GPS, mais dans la capacité à modéliser efficacement la relation complexe entre les signatures radio et la position réelle, malgré la non-linéarité, l’ambiguïté et la forte variabilité du canal radio souterrain. Ce défi justifie l’exploration de techniques avancées d’apprentissage profond afin de construire des modèles de localisation plus robustes, précis et généralisables dans des environnements miniers réels.

1.1.3 Description et analyse de la problématique de propagation en milieu souterrain

Les mines souterraines sont des sites d’exploitation situés en profondeur sous la surface terrestre, permettant l’extraction de ressources minérales enfouies telles que l’or — d’où la ville de Val-d’Or tire son nom — ou encore le cuivre, comme à Rouyn-Noranda. Contrairement aux mines à ciel ouvert, l’accès aux gisements nécessite la construction d’un réseau complexe d’infrastructures souterraines adaptées à la topographie et aux contraintes géologiques.

Un milieu minier souterrain, tel qu’illustré à la Figure 3, se caractérise par un ensemble interconnecté de galeries horizontales (niveaux), de rampes inclinées, de puits verticaux et de cheminées à minerai, conçus pour assurer l’extraction, le transport et la ventilation. L’infrastructure comprend également des systèmes de levage (*skip*), de pompage et d’aérage, indispensables au fonctionnement sécuritaire de l’exploitation. La géométrie irrégulière des tunnels, la présence de structures métalliques, les surfaces rocheuses rugueuses ainsi que les variations de section influencent fortement la propagation des ondes électromagnétiques. Ces caractéristiques font du milieu souterrain un environnement particulièrement contraignant pour les systèmes de communication et de localisation sans fil.

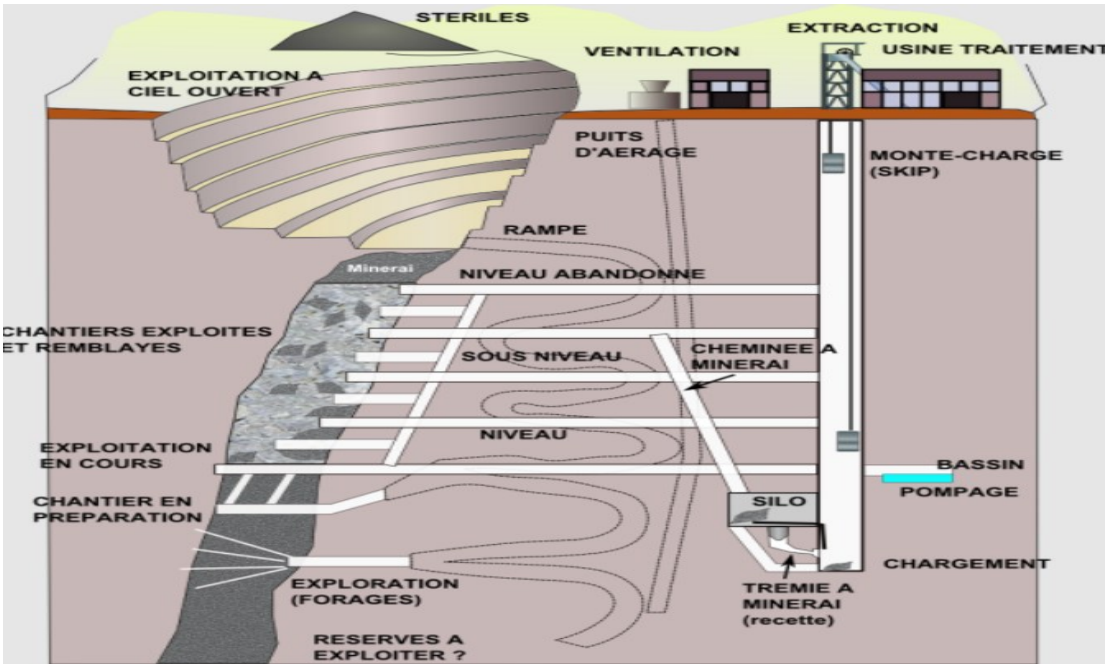

Figure 3
Topologie typique d'une mine

La propagation des ondes radio en milieu souterrain présente des défis spécifiques liés au confinement géométrique des tunnels, aux propriétés électromagnétiques des matériaux et à la présence d'équipements métalliques. Contrairement aux environnements ouverts, les galeries minières agissent comme des structures quasi-guidées où les réflexions multiples sur les parois influencent fortement le champ électromagnétique.

Ce confinement engendre un multichemin structuré et spatialement corrélé, provoquant des variations importantes du signal sur de courtes distances. De plus, les courbures, intersections et conditions de non-visibilité directe (NLOS) accentuent les pertes et la variabilité du signal. Les caractéristiques électriques des roches et des structures métalliques modifient également l'absorption et la réflexion des ondes.

Ainsi, la complexité et la variabilité du milieu minier rendent les modèles empiriques classiques insuffisants, nécessitant des approches déterministes et des calibrations

basées sur des mesures réelles pour garantir une prédiction fiable de la propagation radio et améliorer la précision des systèmes de localisation.

Ces perturbations rendent la relation entre les caractéristiques du signal radio et la position réelle fortement non linéaire, instable et dépendante de l'environnement. En particulier la méthode basée uniquement sur la puissance reçue du signal, perd une partie importante de l'information spatiale et devient insuffisant pour distinguer des positions proches dans des conditions de forte variabilité du canal. Bien que les indicateurs du canal fournissent une description plus fine du canal, sa grande dimensionnalité et sa sensibilité aux variations environnementales rendent son exploitation complexe.

Le principal défi scientifique réside donc dans la capacité à exploiter efficacement ces signatures radio complexes afin de construire un modèle de localisation robuste, précis et généralisable dans des environnements miniers variés, malgré la forte dynamique du canal radio.

1.2 Objectif

Répondre aux défis de la localisation précise en environnement minier souterrain ne consiste pas uniquement à appliquer des méthodes de localisation existantes, mais à concevoir des modèles capables de capturer la relation complexe, non linéaire et instable entre les signatures radio (RSSI et CSI) et la position réelle dans un environnement fortement affecté par la propagation multi-trajets.

L'objectif principal de ce projet est d'étudier la capacité de différentes architectures d'apprentissage profond à modéliser cette relation complexe afin d'améliorer la précision de la localisation bidimensionnelle en milieu minier souterrain. Plus précisément, trois architectures sont développées et évaluées : le Perceptron Multicouche (MLP), le Réseau Neuronal Entièrement Connecté (FCNN) et le Réseau de Mémoire à Court et Long Terme (LSTM), à partir de données expérimentales issues des métriques RSSI et CSI.

Cette étude vise à comparer leur aptitude à extraire des caractéristiques pertinentes du canal radio, à réduire l'ambiguïté induite par les effets de propagation multi-trajets et à améliorer l'estimation de position dans des conditions réelles de propagation souterraine.

Une fois l'architecture la plus performante identifiée, une phase de validation supplémentaire est menée sur de nouveaux jeux de données collectés dans une autre section de la même mine, caractérisée par une géométrie plus complexe et une proportion plus élevée de conditions de non-visibilité directe (NLOS). Cette étape a pour objectif d'évaluer la robustesse, la capacité de généralisation et la stabilité du modèle face à des environnements souterrains non observés, afin de vérifier son potentiel d'application dans des contextes opérationnels réels.

1.3 Hypothèse de recherche et cadre de l'étude

L'hypothèse principale de cette recherche est que les informations contenues dans le CSI, utilisées conjointement avec le RSSI, possèdent un pouvoir discriminant suffisant pour caractériser les différentes conditions de propagation rencontrées dans les sections d'une mine souterraine. Nous postulons que les variations du canal radio, induites par les particularités géométriques et environnementales propres à chaque zone, se reflètent dans ces indicateurs et peuvent être exploitées afin d'identifier les configurations de propagation correspondantes. Compte tenu de la nature complexe et fortement non linéaire des phénomènes de propagation en milieu minier, les réseaux de neurones apparaissent comme une approche particulièrement appropriée pour modéliser ces relations et réaliser la classification des zones de propagation.

Il est toutefois nécessaire de préciser le cadre et les limites de cette étude, qui repose essentiellement sur une démarche expérimentale de collecte et d'analyse de données.

L'étude est réalisée dans un contexte de canal stationnaire, c'est-à-dire qu'aucun mouvement des équipements ou de l'environnement n'est présent durant les campagnes d'acquisition. Les mesures recueillies ne constituent pas des valeurs absolues puisqu'elles dépendent à la fois du matériel utilisé et de la méthodologie de

mesure adoptée. Comme présenté dans la section méthodologique, la géométrie particulière des tunnels miniers ainsi que l'hétérogénéité du milieu peuvent engendrer des erreurs de positionnement lors de la collecte des données. Bien que ces erreurs soient reconnues, elles n'ont pas fait l'objet d'une quantification spécifique dans le cadre de ce travail.

Par ailleurs, le nombre d'échantillons disponibles pour chaque point de mesure n'est pas uniforme, ce qui peut introduire un certain biais lors de l'apprentissage des modèles. Cette variabilité est principalement attribuable aux pertes de liaison observées à certains emplacements, lesquelles résultent des conditions de propagation locales, notamment dans les situations de propagation sans visibilité directe NLOS.

Une étude préliminaire réalisée sur le même site expérimental a permis d'établir les bases de l'utilisation conjointe du RSSI et du CSI pour des applications de localisation en environnement souterrain. Le présent travail s'inscrit dans la continuité de cette démarche en proposant une analyse plus approfondie des performances de différents modèles de réseaux de neurones. Cette analyse repose sur une base de données enrichie comprenant un nombre accru de mesures ainsi qu'un ensemble plus diversifié de sections minières. L'objectif est de favoriser l'apprentissage de caractéristiques représentatives des configurations de propagation couramment rencontrées dans les mines souterraines.

De plus, la méthodologie d'acquisition a été élaborée de manière à reproduire, dans la mesure du possible, les conditions d'utilisation d'un équipement client déployé dans un contexte opérationnel réel. Cette approche permet d'assurer une meilleure représentativité des données utilisées pour l'entraînement et l'évaluation des modèles.

Enfin, le protocole expérimental retenu se limite à une configuration mettant en œuvre un émetteur fixe et un récepteur mobile. Il ne couvre donc pas l'ensemble des configurations possibles où les positions de l'émetteur et du récepteur pourraient varier simultanément. Cette contrainte expérimentale est susceptible de limiter la

capacité des modèles développés à généraliser leurs performances à des scénarios de propagation plus variés.

1.4 Structure du mémoire

Le premier chapitre présente le cadre général de l'étude, en introduisant le contexte des environnements miniers souterrains, la problématique de la localisation sans GPS, ainsi que les motivations et les objectifs poursuivis dans ce travail.

Le deuxième chapitre propose une revue approfondie de la littérature portant sur les méthodes d'apprentissage automatique et d'apprentissage profond appliquées à la localisation intérieure. Les principales approches existantes y sont analysées, en mettant en évidence leurs contributions, leurs performances et leurs limites, notamment dans les environnements contraints.

Le troisième chapitre décrit la méthodologie adoptée pour la conception du système de localisation. Il détaille l'architecture des modèles développés, le dispositif expérimental mis en place, les caractéristiques des jeux de données collectés ainsi que les différentes étapes de prétraitement et de structuration des données utilisées pour l'entraînement et l'évaluation.

Le quatrième chapitre présente les résultats expérimentaux obtenus. Les performances des différents modèles sont analysées de manière comparative à l'aide d'indicateurs quantitatifs pertinents. Une discussion approfondie est menée afin d'évaluer leur robustesse et leur capacité d'adaptation aux contraintes spécifiques de l'environnement minier souterrain.

Enfin, le cinquième chapitre conclut le mémoire en synthétisant les principales contributions scientifiques et techniques de l'étude. Il met en lumière les limites identifiées et leur impact sur les performances du système, tout en proposant des pistes d'amélioration concrètes. Le chapitre ouvre également sur des perspectives de recherche futures visant à renforcer la précision, la robustesse et l'applicabilité opérationnelle du système de localisation.

2. REVUE DE LA LITTÉRATURE

Ce chapitre présente une revue de littérature des principales technologies et approches utilisées pour la localisation dans des environnements où les signaux GPS sont indisponibles, avec une attention particulière portée aux environnements miniers souterrains. L'objectif est d'analyser les solutions existantes, d'identifier leurs avantages ainsi que leurs limitations, et de situer le cadre méthodologique de ce mémoire par rapport aux travaux antérieurs.

Dans un premier temps, les principes de la localisation basée sur le GPS sont présentés, ainsi que les limitations qui rendent cette technologie inadaptée aux environnements souterrains. Ensuite, les principales alternatives de localisation sans fil sont étudiées, notamment les technologies à faible consommation énergétique telles que le ZigBee, le Bluetooth Low Energy (BLE) et *l'Ultra-Wideband* (UWB), ainsi que les approches basées sur des infrastructures radio existantes comme le Wi-Fi et le LTE.

Par la suite, les techniques de localisation basées sur l'exploitation des caractéristiques du signal radio, notamment le RSSI et le CSI, sont analysées, en mettant en évidence leurs mécanismes de fonctionnement, leurs performances ainsi que leurs contraintes dans les environnements complexes.

Enfin, les approches basées sur l'apprentissage automatique et l'apprentissage profond sont examinées afin de montrer leur potentiel pour modéliser les relations complexes entre les caractéristiques du canal radio et la position physique. Cette analyse permet d'identifier les limites des approches existantes et de justifier le choix des architectures neuronales étudiées dans ce mémoire pour la localisation en environnement minier souterrain.

Cette revue constitue ainsi le cadre théorique et scientifique sur lequel repose l'approche expérimentale développée dans les chapitres suivants.

2.1 Localisation dans les environnements sans GPS

Le Système de Positionnement Global (GPS) constitue aujourd'hui la technologie de référence pour la localisation en environnement extérieur, grâce à sa couverture mondiale, sa précision et son intégration dans de nombreux systèmes mobiles et industriels. Son fonctionnement repose sur la réception de signaux émis par une constellation de satellites permettant l'estimation de la position par trilatération.

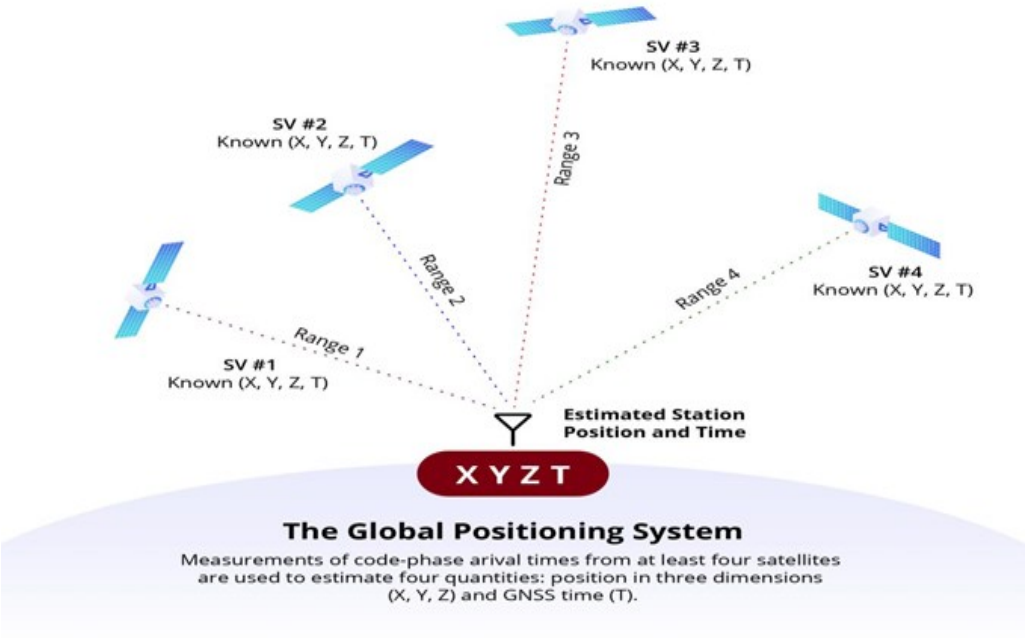

Figure 4
Trilatération basée sur satellite dans le GPS

Le principe du GPS, comme illustré à la figure 4, consiste à mesurer le temps de propagation des signaux entre plusieurs satellites et le récepteur afin de calculer les distances correspondantes. L'intersection de ces distances permet ensuite de déterminer la position de l'utilisateur avec une précision généralement suffisante pour de nombreuses applications civiles et industrielles.[6]

Cependant, malgré son efficacité en environnement extérieur, le GPS présente des limitations importantes dans les environnements souterrains ou confinés. En raison de la forte atténuation des signaux satellitaires à travers les structures rocheuses, les tunnels et les obstacles physiques, les signaux GPS ne peuvent pas pénétrer efficacement dans les mines souterraines. Cette absence de couverture satellitaire rend son utilisation impraticable pour les applications de localisation en milieu minier souterrain.

Cette limitation constitue un défi majeur, puisque la localisation des travailleurs et des équipements représente un élément essentiel pour la sécurité, la coordination opérationnelle et la gestion des interventions d'urgence dans les environnements miniers. Cette contrainte a motivé le développement de technologies alternatives capables d'assurer une localisation fiable sans dépendre de la couverture satellitaire.

2.1.1 Localisation sans fil à faible consommation énergétique

Afin de pallier les limitations du GPS dans les environnements confinés, plusieurs technologies de communication sans fil à faible consommation énergétique ont été développées pour la localisation intérieure et souterraine. Parmi les plus utilisées figurent le *ZigBee,* le *Bluetooth Low Energy* (BLE) et *l'Ultra-Wideband (UWB).*

Le *ZigBee* est une technologie basée sur le standard IEEE 802.15.4, conçue pour les réseaux de capteurs à faible débit et faible consommation énergétique. Son principal avantage réside dans sa simplicité de déploiement ainsi que dans sa faible consommation énergétique.Toutefois, dans un contexte de localisation, Zigbee repose généralement, en pratique, sur des techniques basées sur la puissance du signal reçu (RSSI), dont la précision reste limitée. Bien que d'autres approches puissent être envisagées en théorie, les contraintes matérielles et l'absence d'accès à des informations plus riches sur le canal restreignent leur mise en œuvre. Cette limitation est liée à la faible résolution temporelle des signaux à bande étroite, ainsi qu'à une forte sensibilité aux variations du canal radio. Bien que l'architecture maillée permette d'étendre la couverture, elle nécessite un déploiement dense de nœuds

d’ancrage afin d’améliorer la précision, ce qui peut accroître la complexité et le coût du système.

Le *Bluetooth Low Energy* (BLE) constitue également une solution populaire pour la localisation de proximité grâce à sa faible consommation énergétique et son faible coût d’intégration. Les systèmes BLE reposent généralement sur la mesure du RSSI pour estimer la proximité ou la position. Cependant, comme le ZigBee, le BLE reste fortement sensible aux variations de propagation, aux obstacles physiques et aux interférences, ce qui limite sa précision dans les environnements souterrains complexes[7].

L’Ultra-Wideband (UWB) offre une précision de localisation significativement supérieure grâce à sa largeur de bande et à l’utilisation de techniques de mesure temporelle telles que le Time of Flight (ToF) et l’Angle of Arrival (AoA). Ces techniques permettent une estimation précise de la distance entre les nœuds. Cependant, malgré cette précision élevée, l’UWB nécessite généralement une infrastructure dédiée, une synchronisation précise entre les dispositifs ainsi qu’un matériel spécialisé, ce qui augmente les coûts de déploiement et de maintenance dans les environnements miniers[8].

Ainsi, bien que ces technologies présentent des avantages intéressants en matière de consommation énergétique ou de précision, leurs limitations en termes de portée, de robustesse ou de coût rendent leur adoption plus complexe dans les réseaux miniers souterrains à grande échelle.

2.1.2 Localisation basée sur une infrastructure radio existante

Contrairement aux technologies de localisation nécessitant une infrastructure dédiée, certaines approches reposent sur l’exploitation d’infrastructures de communication déjà présentes dans les environnements industriels, telles que le Wi-Fi et les réseaux cellulaires privés comme le LTE.

L’un des principaux avantages de ces technologies réside dans la réutilisation d’une infrastructure de communication existante, ce qui réduit considérablement les coûts

de déploiement et facilite leur intégration dans les systèmes industriels. De plus, ces technologies offrent une couverture plus large que les systèmes low-power, ce qui représente un avantage important dans les réseaux miniers souterrains étendus.

Le LTE offre une couverture importante et une bonne robustesse de communication, ce qui le rend adapté aux applications industrielles nécessitant une connectivité fiable. Toutefois, l'accès aux informations détaillées du canal radio reste souvent limité par les contraintes imposées par les équipements commerciaux et les opérateurs réseau, ce qui réduit sa flexibilité pour les applications avancées de localisation.

Le Wi-Fi, quant à lui, constitue une solution particulièrement attractive pour la localisation, en raison de sa large disponibilité, de son faible coût et de sa facilité de déploiement. Contrairement au LTE, il permet un accès direct à plusieurs indicateurs radio exploitable pour la localisation, notamment le RSSI et le CSI. Cette richesse d'information permet une meilleure exploitation des caractéristiques du canal, en particulier dans les environnements complexes où les phénomènes de multi-trajets et les conditions NLOS sont fortement présents.

Ainsi, parmi les technologies basées sur une infrastructure radio existante, le Wi-Fi apparaît comme une solution particulièrement adaptée à la localisation dans les mines souterraines, en offrant un compromis efficace entre coût, couverture, accessibilité des données et potentiel de précision.

2.1.3 Techniques de localisation basées sur le signal

Une première catégorie d'études s'est intéressée à la comparaison entre le RSSI et le CSI dans les systèmes de localisation intérieure. Ces travaux reposent généralement sur une approche de fingerprinting, qui consiste à collecter des signatures radio à différentes positions connues afin de constituer une base de référence. Lors de la phase de localisation, les nouvelles mesures sont comparées à cette base pour estimer la position. Les résultats montrent que le RSSI est simple à acquérir et peu coûteux à exploiter, mais reste fortement affecté par les fluctuations du canal radio, les phénomènes de multi-trajets et les changements environnementaux. En revanche, le CSI offre une représentation plus détaillée du

canal grâce aux amplitudes et phases des sous-porteuses du signal WiFi, permettant une meilleure précision de localisation. Cependant, cette approche nécessite une phase de collecte de données importante et une mise à jour fréquente de la base d'empreintes lorsque l'environnement évolue, ce qui limite son adaptation aux environnements dynamiques comme les mines souterraines.

Dans le contexte des mines souterraines, certaines études ont proposé des approches basées sur le RSSI collaboratif, une méthode où plusieurs nœuds d'ancrage coopèrent en partageant leurs mesures de puissance reçue afin d'améliorer l'estimation de position. Ces approches combinent généralement des techniques telles que le filtrage de Kalman, la correction dynamique du modèle de propagation ainsi que la fusion des mesures RSSI provenant de plusieurs points d'ancrage pour stabiliser les estimations et améliorer la couverture de localisation. Bien que cette stratégie améliore la robustesse du système, elle présente plusieurs limitations dans les environnements miniers souterrains. En effet, elle nécessite le déploiement d'un nombre important de nœuds d'ancrage, ce qui augmente les coûts d'installation, de maintenance et d'alimentation. De plus, la géométrie complexe des tunnels, la présence d'équipements métalliques, les bifurcations ainsi que l'évolution continue de l'environnement minier peuvent perturber les liens radio et dégrader la qualité des mesures RSSI[9].

Ainsi, malgré les progrès réalisés, les approches basées sur le fingerprinting ou sur le RSSI collaboratif restent limitées par leur dépendance à la stabilité de l'environnement ou à une infrastructure dense et coûteuse.

2.1.4 Apprentissage automatique et apprentissage profond pour la localisation

L'apprentissage automatique (*Machine Learning*, ML) est devenu un outil central dans les systèmes de localisation sans fil, particulièrement dans les environnements où les approches traditionnelles basées sur des modèles physiques rencontrent des difficultés liées aux effets de multi-trajets, aux variations dynamiques du canal radio et aux conditions de non-visibilité directe (NLOS). Contrairement aux méthodes déterministes, les approches basées sur l'apprentissage permettent d'apprendre

directement la relation entre les caractéristiques du signal radio et la position physique à partir de données expérimentales[10].

Les approches d'apprentissage appliquées à la localisation sans fil peuvent être regroupées en deux grandes catégories : les méthodes traditionnelles d'apprentissage automatique et les méthodes d'apprentissage profond. Comme illustré à la Figure 5, ces approches peuvent être formulées selon deux paradigmes principaux : la classification et la régression.

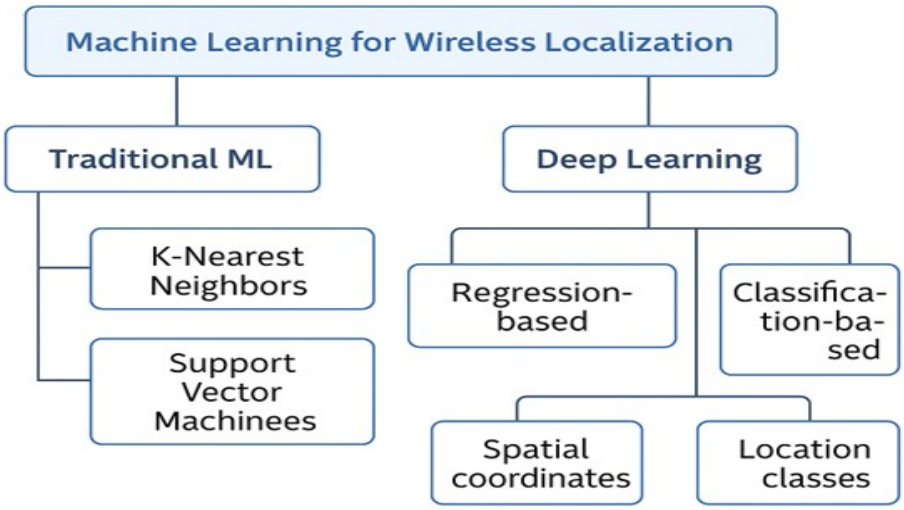

Figure 5
Catégories de techniques d'apprentissage automatique dans la localisation sans fil.

Dans les approches basées sur la classification, l'environnement est divisé en zones discrètes ou en points de référence prédéfinis, et le modèle attribue à chaque nouvelle mesure la classe de localisation la plus probable. Cette stratégie simplifie le problème de localisation, mais sa précision dépend fortement de la granularité du découpage spatial.

À l'inverse, les approches basées sur la régression permettent de prédire directement les coordonnées spatiales continues, généralement sous la forme (x,y), à partir des caractéristiques du signal. Cette formulation offre une estimation plus fine de la

position et s'avère particulièrement adaptée aux applications nécessitant une localisation précise.

Parmi les approches traditionnelles d'apprentissage automatique, les algorithmes tels que le *K-Nearest Neighbors* (KNN) et les *Support Vector Machines* (SVM) ont été largement utilisés dans les systèmes de localisation basés sur le fingerprinting[11]. Le KNN estime la position en comparant la signature radio courante avec les empreintes les plus proches présentes dans la base de données, tandis que le SVM construit des frontières de décision dans un espace de caractéristiques de grande dimension afin d'améliorer la séparation entre différentes zones de localisation.

Ces méthodes ont montré des performances satisfaisantes dans plusieurs travaux de localisation intérieure, en particulier dans des environnements relativement stables et bien calibrés. Cependant, leurs performances restent étroitement liées à la qualité des caractéristiques extraites ainsi qu'à la représentativité des données d'entraînement, notamment lorsque les conditions de propagation deviennent fortement variables ou complexes.

En parallèle, plusieurs travaux récents ont exploré l'utilisation de modèles d'apprentissage profond dans les systèmes de localisation sans fil. Contrairement aux approches traditionnelles, ces architectures permettent l'extraction automatique de représentations plus complexes à partir des données brutes, réduisant ainsi la dépendance à une ingénierie manuelle des caractéristiques[12].

Certaines études ont notamment exploité le CSI combiné à des architectures profondes avancées, telles que *Residual Neural Network* et *Vision Transformer*, afin de modéliser les relations complexes entre les caractéristiques du canal radio et la position physique. Ces approches appliquent généralement un prétraitement du CSI, incluant le nettoyage des amplitudes et la correction des erreurs de phase, avant d'utiliser des architectures profondes pour extraire automatiquement les caractéristiques pertinentes du canal radio[13].

Ces stratégies ont montré des résultats prometteurs dans plusieurs scénarios expérimentaux. Toutefois, leur efficacité dépend fortement de la disponibilité de jeux de données représentatifs et suffisamment diversifiés, ce qui constitue une contrainte importante dans les environnements miniers souterrains où la collecte de données est complexe et coûteuse.

Dans le cadre de ce mémoire, la localisation est formulée comme un problème de régression, puisque l'objectif est d'estimer directement les coordonnées spatiales continues à partir des mesures RSSI et CSI. L'approche proposée repose sur l'évaluation comparative de réseaux de neurones plus adaptés au compromis entre précision, complexité et capacité de généralisation, notamment le MLP, le FCNN et le LSTM, appliqués à des données réelles collectées dans une mine souterraine.

L'objectif est d'évaluer leur précision, leur robustesse ainsi que leur capacité de généralisation dans différentes sections minières présentant des conditions de propagation variées. Pour ce faire, nous mettons en œuvre une démarche en plusieurs phases, allant de l'acquisition des données sur site à la configuration des réseaux de neurones, comme l'illustre la Figure 6.

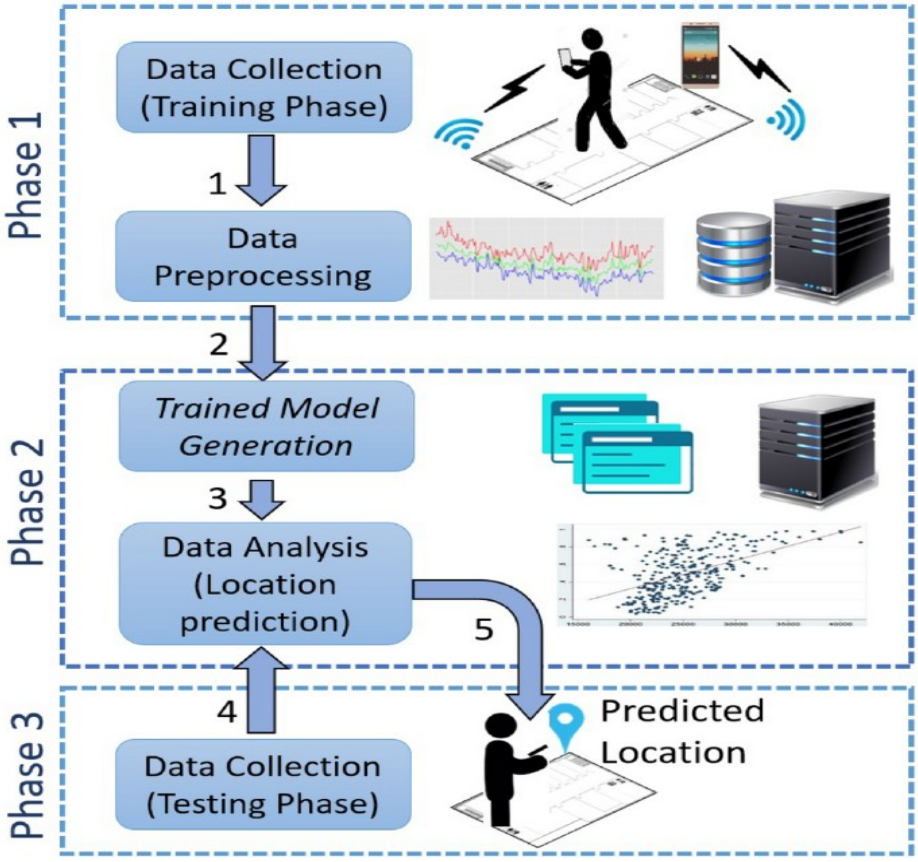

Figure 6
Schéma de fonctionnement d'un système de localisation par apprentissage Automatique basé sur le signal.

2.2 Les Perceptrons Multicouches (MLP)

2.2.1 Principe général du MLP

Le MLP est une architecture fondamentale des réseaux de neurones artificiels appartenant à la famille des modèles *feedforward* entièrement connectés. Il est composé d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie, comme le montre la figure 7. Chaque neurone d'une couche est relié à l'ensemble des neurones de la couche suivante à travers des poids ajustables, permettant ainsi l'apprentissage de relations complexes entre les variables d'entrée et les sorties[14].

Dans le cadre de ce travail, le MLP est utilisé pour modéliser la relation non linéaire entre les caractéristiques radios mesurés, notamment le RSSI et les composantes amplitude et phase du CSI, et les coordonnées spatiales de l'émetteur dans un tunnel minier souterrain. Le problème est formulé comme une tâche de régression continue visant à estimer les coordonnées cartésiennes (X, Y) ou polaires (r, θ).

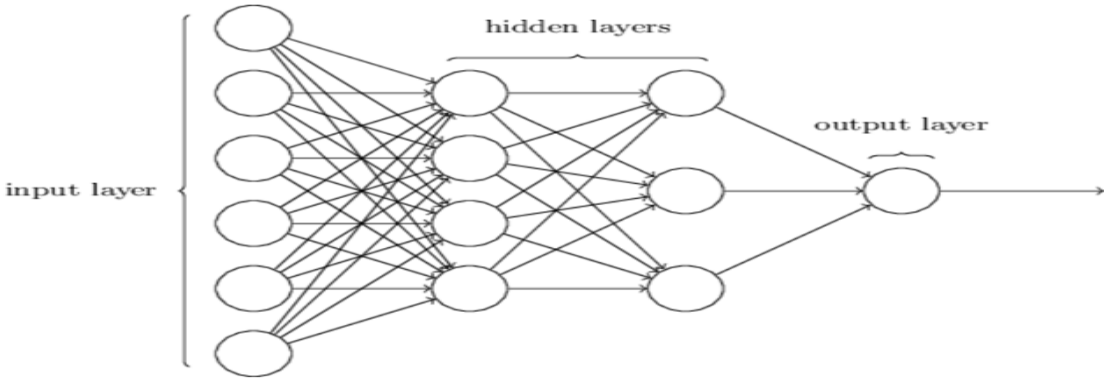

Figure 7
Architecture du réseau de neurones MLP

2.2.2 Formulation mathématique

Le fonctionnement interne du MLP repose sur une succession de transformations linéaires suivies d'activations non linéaires.

Pour une couche cachée l, la transformation s'écrit :

$$\begin{aligned} \mathbf{z}^{(l)} &= \mathbf{W}^{(l)}\mathbf{a}^{(l-1)} + \mathbf{b}^{(l)} \\ \mathbf{a}^{(l)} &= \phi\left(\mathbf{z}^{(l)}\right) \end{aligned} \tag{1}$$

où:

- $\mathbf{W}^{(l)} \in \mathbb{R}^{n_l \times n_{l-1}}$Est la matrice des poids,
- $\mathbf{b}^{(l)} \in \mathbb{R}^{n_l}$ est le vecteur biais,
- $\mathbf{a}^{(l-1)}$ est la sortie de la couche précédente,
- $\phi(\cdot)$ est la fonction d'activation.

La couche de sortie, adaptée à un problème de régression continue, utilise une activation linéaire :

$$\hat{\mathbf{y}} = \mathbf{W}^{(L)}\mathbf{a}^{(L-1)} + \mathbf{b}^{(L)} \quad (2)$$

Où $\hat{\mathbf{y}}$ correspond aux coordonnées estimées.

La non-linéarité introduite par la fonction d'activation est essentielle. Sans celle-ci, l'ensemble du réseau serait équivalent à une simple transformation linéaire, incapable de modéliser la complexité du canal radio en environnement minier[15]. Les fonctions d;activation les plus utilisee sont sigmoïde, tanh et ReLU. En pratique, dans les couches intermédiaires, on privilégie généralement une activation comme ReLU (ou ses variantes). Elle est bien adaptée car elle introduit une non-linéarité efficace sans saturer pour les valeurs positives, ce qui facilite la propagation du gradient dans les réseaux de régression. Contrairement à la sigmoïde ou à tanh, elle limite les problèmes de gradient qui disparaît et permet une convergence plus rapide et stable.

2.2.3 Fonction de coût et optimisation

L'apprentissage du MLP consiste à minimiser l'écart entre les positions réelles et les positions estimées. Dans ce travail, l'erreur quadratique moyenne (*Mean Squared Error*, MSE) est utilisée :

$$\mathcal{L}(\theta) = \frac{1}{N}\sum_{i=1}^{N} \| \mathbf{y}_i - \hat{\mathbf{y}}_i \|^2 \quad (3)$$

où :

- $\mathbf{y}_i$Est la position réelle,
- $\hat{\mathbf{y}}_i$Est la position prédite,
- NEst le nombre total d'échantillons.

L'optimisation des paramètres s'effectue par rétropropagation du gradient :

$$\theta \leftarrow \theta - \eta \nabla_\theta \mathcal{L} \quad (4)$$

Où η est le taux d'apprentissage. Dans notre implémentation, l'algorithme Adam est utilisé afin d'améliorer la stabilité et la vitesse de convergence.

2.2.4 Capacité d'approximation

Selon le théorème d'approximation universelle, un MLP comportant au moins une couche cachée et une fonction d'activation non linéaire peut approximer toute fonction continue sur un domaine compact avec une précision arbitraire.

Cette propriété est particulièrement importante dans le contexte de la localisation en mine souterraine, où la relation entre les caractéristiques radio et la position est fortement non linéaire :

$$\left(RSSI, CSI_{amp}, CSI_{phase}\right) \rightarrow (X, Y) \quad (5)$$

2.2.5 Complexité paramétrique et limites du MLP

Le nombre de paramètres d'une couche reliant n_{l-1}neurones à $n_l$neurones est donné par :

$$n_l \times n_{l-1} + n_l \quad (6)$$

Ainsi, pour un vecteur d'entrée de dimension 129 (64 amplitudes + 64 phases + 1 RSSI) et une première couche cachée de 256 neurones, le nombre de paramètres est :

$$256 \times 129 + 256$$

Cette forte capacité paramétrique permet d'apprendre des relations complexes mais augmente également le risque de surapprentissage.

2.2.6 Application au fingerprinting/localisation CSI

Toutefois, malgré sa puissance d'approximation, le MLP présente certaines limites structurelles : il traite les entrées comme un vecteur plat sans exploiter explicitement la structure fréquentielle du CSI, les corrélations locales entre sous-porteuses ni les dépendances séquentielles éventuelles. Dans un environnement minier souterrain caractérisé par une propagation complexe et fortement dépendante de la géométrie du tunnel, ces limitations peuvent restreindre sa capacité de généralisation, justifiant ainsi la comparaison avec des architectures plus adaptées telles que le FCNN optimisé et le LSTM.

2.3 Les Réseaux Neuronaux Entièrement Convolutionnels (FCNN)

2.3.1 Principe général du FCNN

Le réseau FCNN (figure 8) constitue une extension des réseaux de neurones convolutionnels (CNN) traditionnels. Contrairement aux CNN classiques qui se terminent par des couches entièrement connectées destinées à la classification, le FCNN remplace ces couches par des couches convolutionnelles, permettant ainsi de générer des sorties de taille arbitraire tout en conservant la structure spatiale des données d'entrée [16].

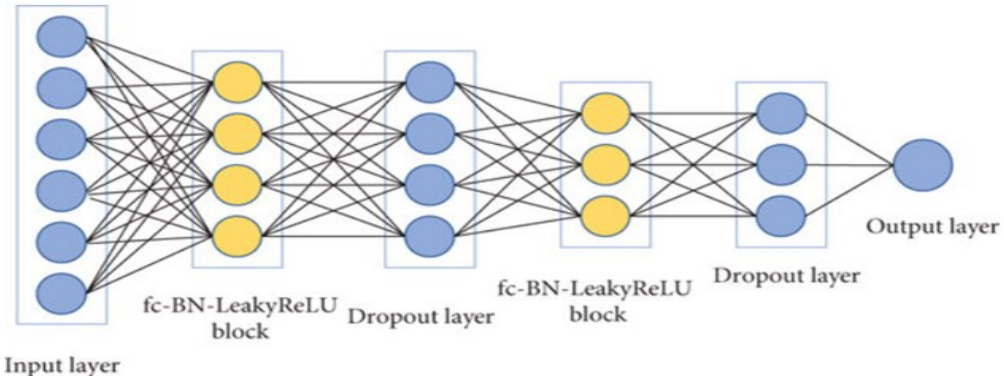

Figure 8
Architecture du réseau de neurones FCNN

Dans le cadre de la localisation basée sur CSI, le FCNN exploite la structure matricielle des données CSI afin d'extraire des caractéristiques locales pertinentes. Cette capacité est particulièrement adaptée aux matrices CSI, où les sous-porteuses

présentent des corrélations fréquentielles liées aux phénomènes physiques de propagation.

2.3.2 Opération de convolution

Le cœur du FCNN repose sur l'opération de convolution. Pour une carte d'entrée Xet un filtre convolutionnel K, la sortie Yest donnée par :

$$Y(i,j) = \sum_{m} \sum_{n} X(i-m, j-n)\, K(m,n) \tag{7}$$

Cette opération permet au réseau d'extraire des motifs locaux dans les données, tels que des variations cohérentes d'amplitude ou de phase entre sous-porteuses adjacentes [17].

La sortie d'une couche convolutionnelle s'écrit généralement :

$$\mathbf{A}^{(l)} = \phi\left(\mathbf{W}^{(l)} * \mathbf{A}^{(l-1)} + \mathbf{b}^{(l)}\right) \tag{8}$$

où :

- $*$ représente l'opération de convolution,
- $\mathbf{W}^{(l)}$ est l'ensemble des filtres appris,
- $\phi(\cdot)$ est la fonction d'activation non linéaire.

2.3.3 Préservation de la structure spatiale

Contrairement au MLP, qui traite les données d'entrée comme un vecteur plat, le FCNN conserve la structure spatiale des données à travers l'ensemble des couches convolutionnelles. Cette propriété est particulièrement importante dans le cas des matrices CSI, où l'organisation fréquentielle des sous-porteuses contient une information physique pertinente

En effet, les sous-porteuses adjacentes présentent généralement une corrélation fréquentielle due aux phénomènes de propagation. Les variations locales d'amplitude

et de phase reflètent les effets du multi-trajet, des réflexions sur les parois rocheuses et des interactions avec les obstacles métalliques. Ainsi, les motifs locaux observés dans la matrice CSI peuvent correspondre à des configurations spécifiques de propagation dans le tunnel.

En préservant cette structure, le FCNN exploite explicitement la topologie des données, ce qui améliore la capacité d'extraction de caractéristiques pertinentes pour l'estimation de position.

2.3.4 Application au fingerprinting CSI

Dans les systèmes de localisation par fingerprinting, chaque position spatiale est associée à une signature radio unique. Le FCNN apprend alors une fonction de cartographie reliant directement la matrice CSI aux coordonnées spatiales :

$$f_\theta : CSI \rightarrow (X, Y) \tag{9}$$

Où θ représente l'ensemble des paramètres du réseau.

Grâce aux opérations de convolution, le FCNN extrait automatiquement des caractéristiques discriminantes à partir des matrices CSI. Son efficacité repose principalement sur sa capacité à capturer les corrélations locales entre sous-porteuses, à réduire l'impact du bruit par l'effet des filtres convolutifs et à maintenir la résolution spatiale jusqu'à la couche de sortie.

Cette architecture a démontré de bonnes performances dans les systèmes de localisation intérieure basés sur CSI, notamment dans des environnements complexes caractérisés par un fort multi-trajet[18].

2.3.5 Avantages et limites du FCNN en environnement minier

Dans un tunnel minier souterrain, la propagation radio est fortement influencée par la géométrie tridimensionnelle du corridor, les réflexions multiples, les effets de guide d'onde et la présence d'équipements métalliques. Les variations locales du CSI contiennent ainsi des signatures spatiales directement liées à ces phénomènes physiques.

Le FCNN est particulièrement adapté à ce contexte, car il exploite la structure fréquentielle du CSI et capture efficacement les motifs locaux associés au multi-trajet, tout en réduisant le nombre de paramètres par rapport à un MLP entièrement connecté de taille équivalente, ce qui améliore généralement sa robustesse face au bruit. Toutefois, bien qu'il modélise efficacement les dépendances locales dans la dimension fréquentielle, le FCNN ne capture pas explicitement les dépendances temporelles longues entre mesures successives, et ses performances restent sensibles au choix des hyperparamètres tels que la taille des filtres et le nombre de couches convolutionnelles. Pour ces raisons, il est comparé dans cette étude au MLP et au LSTM afin d'évaluer sa capacité à modéliser la relation complexe entre CSI, RSSI et position dans un environnement minier caractérisé par une propagation radio fortement non linéaire.

2.4 Réseau à Mémoire à Court Terme Longue (LSTM)

2.4.1 Principe général des LSTM

Les réseaux LSTM (figure 9) constituent une architecture spécialisée des réseaux neuronaux récurrents (RNN), conçue pour traiter efficacement les données séquentielles. Contrairement aux réseaux *feedforward* classiques, les LSTM possèdent une mémoire interne leur permettant de conserver et d'exploiter des informations issues d'états précédents[19].

Dans le contexte de la localisation basée sur RSSI ou CSI, les LSTM sont particulièrement adaptés lorsque les données sont collectées sous forme de séquences temporelles. Ils permettent d'exploiter les dépendances temporelles présentes dans les variations du signal radio, améliorant ainsi la robustesse du modèle dans des environnements dynamiques.

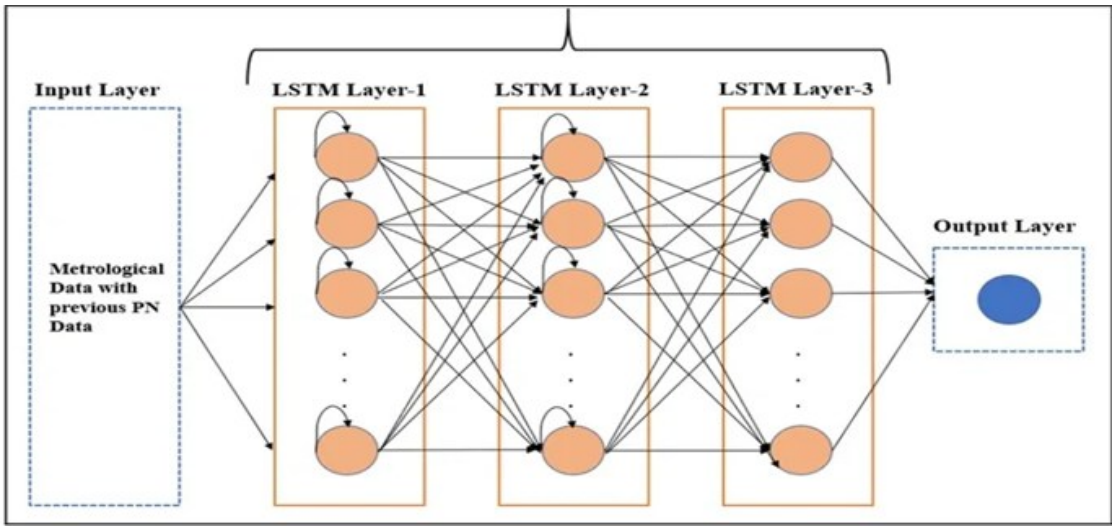

Figure 9
Architecture du réseau de neurones LSTM

2.4.2 Structure interne d'une cellule LSTM

Une cellule LSTM est composée de trois mécanismes principaux appelés portes (*gates*), qui permettent de contrôler le flux d'information à travers la cellule et de gérer la mémoire du réseau. Ces portes sont :

- Porte d'oubli (*forget gate*): : elle détermine quelles informations de l'état précédent doivent être conservées ou supprimées.
- Porte d'entrée *(input gate):* elle contrôle quelles nouvelles informations doivent être ajoutées à l'état de la cellule.
- Porte de sortie (*output gate*) : elle décide quelles informations de l'état interne doivent être utilisées pour produire la sortie de la cellule.

Ces portes contrôlent le flux d'information à travers l'état interne de la cellule [20].

Les équations fondamentales d'une cellule LSTM sont les suivantes :

Porte d'oubli :

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (10)$$

Porte d'entrée :

$$\tilde{C}_t = \tanh\left(W_c x_t + U_c h_{t-1} + b_c\right) \quad (11)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (12)$$

Mise à jour de l'état mémoire :

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (13)$$

Porte de sortie:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (14)$$

$$h_t = o_t \odot \tanh\left(C_t\right) \quad (15)$$

où:

- x_t est l'entrée au temps t,
- h_t est l'état caché,
- C_t est l'état mémoire,
- σ est la fonction sigmoïde,
- $\odot$ Représente le produit élément par élément.

Cette architecture permet au LSTM de conserver des informations pertinentes sur de longues séquences et d'éviter le problème du gradient évanescent rencontré dans les RNN classiques [21].

2.4.3 Application à la localisation basée sur RSSI et CSI

Dans un système de localisation souterrain, les mesures RSSI ou CSI peuvent être collectées de manière séquentielle le long d'un corridor ou lors d'un déplacement de l'émetteur. Les variations successives du signal contiennent une information temporelle liée à la géométrie du tunnel et aux phénomènes de propagation.

Le LSTM apprend alors une fonction de type :

$$f_\theta : (x_1, x_2, \ldots, x_T) \rightarrow (X, Y) \quad (16)$$

Où la position estimée dépend de l'ensemble de la séquence d'observations et non d'une seule mesure isolée.

2.4.4 Avantages et limites du LSTM en environnement minier

Dans un tunnel minier, les variations du signal radio sont influencées par le mouvement, la présence d'équipements mobiles et les changements locaux de géométrie, ce qui introduit des dépendances temporelles dans les mesures RSSI et CSI. Les LSTM sont particulièrement adaptés à ce contexte, car ils exploitent ces dépendances en intégrant l'information provenant de plusieurs mesures successives, ce qui permet d'obtenir une estimation de position plus stable et moins sensible aux fluctuations instantanées du canal.

Toutefois, cette architecture présente une complexité computationnelle plus élevée que le MLP ou le FCNN et nécessite un volume suffisant de données séquentielles pour exploiter pleinement sa capacité mémoire. De plus, lorsque les mesures ne présentent pas de dépendances temporelles significatives, l'utilisation d'un LSTM peut ne pas apporter d'amélioration notable par rapport aux architectures non récurrentes. Dans cette étude, le LSTM est ainsi comparé au MLP et au FCNN afin d'évaluer l'apport réel de la modélisation temporelle pour la localisation basée sur RSSI et CSI en environnement minier souterrain.

2.4.5 Principes de généralisation des réseaux

Pour améliorer la généralisation d'un MLP, plusieurs techniques complémentaires sont couramment utilisées afin de réduire le surapprentissage et stabiliser l'entraînement.

La normalisation des données consiste à mettre les variables d'entrée sur une même échelle (par exemple moyenne nulle et variance unitaire). Cela évite qu'une variable

domine les autres et facilite l'optimisation par descente de gradient, en rendant la surface de perte plus régulière.

Le *dropout* est une technique de régularisation qui désactive aléatoirement une fraction des neurones pendant l'entraînement. Cela empêche le réseau de trop dépendre de certaines connexions et force l'apprentissage de représentations plus robustes et redondantes.

La *Batch Normalization* normalise les activations intermédiaires au sein d'un mini-batch, en recentrant et redimensionnant les sorties des couches. Cela réduit le problème de décalage de distribution interne (*internal covariate shift*), accélère la convergence et permet souvent d'utiliser des taux d'apprentissage plus élevés.

Enfin, l'*early stopping* consiste à surveiller la performance sur un jeu de validation et à arrêter l'entraînement dès que celle-ci se dégrade, même si la performance sur le jeu d'entraînement continue de s'améliorer. Cette méthode permet de sélectionner implicitement le modèle au meilleur compromis entre biais et variance.

2.5 Apprentissage profond supervisé pour la localisation en environnements miniers souterrains

Les systèmes de localisation fondés sur l'apprentissage profond reposent généralement sur un apprentissage supervisé, dans lequel le modèle ajuste ses paramètres afin de minimiser l'écart entre les positions prédites et les positions de référence mesurées. L'efficacité de ce processus dépend fortement de la quantité, de la diversité et de la représentativité des données disponibles. Un jeu d'entraînement couvrant un large éventail de positions, de configurations géométriques et de variations environnementales améliore significativement la précision ainsi que la capacité de généralisation du modèle. Lorsque les données sont limitées, des stratégies telles que l'apprentissage par transfert ou l'augmentation de données peuvent être mises en œuvre afin d'accroître la robustesse du système [22].

Dans les environnements miniers souterrains, l'adaptation des modèles d'apprentissage profond revêt une importance particulière en raison de l'atténuation

marquée du signal, des conditions fréquentes de non-visibilité directe (NLOS) et de la géométrie complexe et irrégulière des tunnels. Les architectures modernes, telles que les réseaux neuronaux entièrement connectés (FCNN) et les réseaux à mémoire longue à court terme (LSTM), offrent une capacité d'extraction de caractéristiques particulièrement adaptée à la modélisation de ces comportements non linéaires. Lorsqu'ils sont correctement entraînés et calibrés, ces modèles peuvent fournir une localisation plus stable et plus précise que les méthodes traditionnelles d'apprentissage automatique.

2.6 Défis liés à l'application de l'apprentissage profond à la localisation

L'intégration de modèles d'apprentissage profond dans des systèmes de localisation opérationnels demeure un défi majeur, malgré leurs performances prometteuses en environnement contrôlé. Ces difficultés sont principalement liées aux exigences élevées en matière de collecte de données représentatives, à la stabilité du processus d'entraînement et à la robustesse du modèle lors de son déploiement en conditions réelles.

Tout d'abord, les modèles d'apprentissage profond nécessitent des ensembles de données volumineux, diversifiés et soigneusement annotés afin de capturer la variabilité spatiale et temporelle du canal radio. Dans les environnements souterrains, la collecte de telles données peut s'avérer coûteuse, chronophage et parfois difficile d'accès en raison des contraintes opérationnelles et de sécurité. De plus, les conditions de propagation peuvent évoluer au fil du temps (présence d'équipements mobiles, humidité, changements structurels), entraînant une dérive des données (data drift) susceptible de dégrader les performances du modèle.

Ensuite, la stabilité de l'entraînement constitue un enjeu important. Les données issues du RSSI et du CSI sont souvent bruitées, non stationnaires et fortement corrélées, ce qui peut conduire à des problèmes de surapprentissage ou à une convergence instable si le modèle n'est pas correctement régularisé. Le choix de l'architecture, des hyperparamètres, des techniques de normalisation et des stratégies de validation joue donc un rôle déterminant dans la fiabilité du système.

Enfin, la généralisation en environnement réel représente l'un des principaux défis. Les environnements miniers souterrains se caractérisent par une propagation multi-trajets extrême, des conditions fréquentes de non-visibilité directe (NLOS) et des géométries irrégulières qui complexifient la relation entre le signal et la position. Un modèle performant dans une section donnée du tunnel peut voir ses performances diminuer lorsqu'il est appliqué à une autre section présentant des caractéristiques différentes.

Ces contraintes soulignent la nécessité de concevoir des architectures robustes, de mettre en place des protocoles expérimentaux rigoureux et d'intégrer des mécanismes d'adaptation ou de recalibration afin d'assurer une localisation fiable et durable dans les réseaux miniers souterrains.

2.6.1 Contraintes liées à la collecte de données

Les modèles d'apprentissage profond reposent sur la disponibilité de volumes importants de données annotées et représentatives afin d'assurer un apprentissage robuste et une bonne capacité de généralisation. Dans le contexte des environnements souterrains, la collecte de telles données constitue un défi majeur, tant sur le plan technique que logistique. Contrairement aux environnements extérieurs ou aux espaces intérieurs classiques, les mines souterraines présentent des contraintes opérationnelles strictes qui rendent les campagnes de mesure longues, coûteuses et exigeantes en main-d'œuvre.

La géométrie confinée des tunnels, la présence d'équipements lourds, les surfaces métalliques, l'humidité variable ainsi que les conditions de sécurité strictes compliquent l'installation des dispositifs de mesure et la répétabilité des expérimentations. De plus, les phénomènes de propagation par trajets multiples, particulièrement prononcés en milieu minier, exigent une densité d'échantillonnage élevée pour capturer fidèlement la variabilité spatiale du canal radio. Cela implique souvent la réalisation de mesures à intervalles réguliers et sur de multiples configurations, ce qui augmente considérablement le temps de collecte.

Par ailleurs, les données acquises dans une section spécifique d'un tunnel ne sont pas nécessairement transférables à d'autres environnements souterrains présentant des géométries, des matériaux ou des conditions opérationnelles différentes. Cette dépendance au site limite la capacité de généralisation des modèles et peut nécessiter des campagnes de recalibration fréquentes. Ainsi, la constitution d'un jeu de données suffisamment diversifié et représentatif demeure l'un des principaux obstacles à l'industrialisation des solutions de localisation basées sur l'apprentissage profond en milieu minier.

2.6.2 Variabilité environnementale et effets de trajets multiples

Les environnements souterrains se caractérisent par une propagation électromagnétique particulièrement complexe, dominée par des phénomènes de trajets multiples (*multipath*) et par un affaiblissement du signal difficilement prévisible. La géométrie irrégulière des tunnels, la rugosité des parois rocheuses, la présence d'infrastructures métalliques ainsi que la circulation de machinerie lourde contribuent à la réflexion, à la diffraction et à la diffusion des ondes radio. Ces interactions multiples modifient continuellement l'amplitude et la phase du signal reçu [23].

À ces effets structurels s'ajoutent des facteurs dynamiques tels que les déplacements d'équipements, l'activité humaine, les variations d'humidité et les changements opérationnels, qui introduisent une variabilité temporelle significative du canal radio. Ces fluctuations se traduisent par un bruit important dans les caractéristiques de signal exploitées pour la localisation, notamment le RSSI et le CSI. Par conséquent, la relation entre les mesures radio et la position physique devient fortement non linéaire et instable, ce qui complique l'apprentissage de correspondances précises et robustes.

Cette variabilité environnementale peut ralentir la convergence des modèles d'apprentissage et accroître le risque de surapprentissage lorsque le modèle capture des configurations spécifiques plutôt que des tendances généralisables. Bien que certaines architectures profondes, telles que les LSTM, soient capables de modéliser des dépendances temporelles et d'exploiter l'information séquentielle, leur

performance peut demeurer sensible aux changements mineurs ou soudains de l'environnement. Garantir des performances constantes et stables dans des conditions opérationnelles réelles constitue ainsi un défi central pour les systèmes de localisation basés sur l'apprentissage profond en milieu souterrain.

2.6.3 Surapprentissage et généralisation

Dans un contexte minier souterrain, cette problématique est particulièrement critique. Un modèle entraîné dans une section donnée d'un tunnel peut ne pas maintenir le même niveau de précision dans une autre section présentant une géométrie différente, des matériaux distincts ou une densité variable d'équipements métalliques. De plus, les environnements souterrains sont dynamiques : l'installation de nouveaux équipements, les déplacements de machinerie, les variations d'humidité ou encore les changements de température peuvent modifier les caractéristiques du canal radio au fil du temps. Ces évolutions entraînent une dérive des données (*data drift*), qui peut réduire progressivement la fiabilité des prédictions si le modèle n'est pas adapté.

Pour atténuer ces effets, plusieurs stratégies peuvent être envisagées. Le réentraînement périodique du modèle à partir de nouvelles données permet de maintenir ses performances, mais implique des campagnes de mesure supplémentaires. Des approches plus avancées, telles que le transfert d'apprentissage (*transfer learning*) ou l'adaptation de domaine (*domain adaptation*), peuvent également être utilisées afin d'améliorer la capacité du modèle à s'adapter à de nouveaux environnements avec un nombre limité de données additionnelles. La mise en œuvre de techniques de régularisation, de validation croisée rigoureuse et d'augmentation de données constitue également un levier important pour limiter le surapprentissage et renforcer la robustesse globale du système.

Ainsi, la maîtrise du compromis entre performance locale et capacité de généralisation demeure un enjeu central dans le déploiement fiable des systèmes de localisation basés sur l'apprentissage profond en environnement souterrain.

2.6.4 Complexité des modèles et contraintes matérielles

Les modèles d'apprentissage profond, en particulier ceux comportant un grand nombre de couches ou des architectures récurrentes telles que les LSTM, présentent une complexité computationnelle élevée. Leur entraînement nécessite des ressources matérielles importantes, notamment en termes de puissance de calcul et de mémoire, tandis que leur déploiement en phase d'inférence peut également engendrer une latence significative.

Dans le contexte des applications de localisation en milieu souterrain, ces contraintes prennent une dimension particulière. Les systèmes destinés au suivi du personnel ou des équipements doivent fonctionner en temps réel ou quasi-temps réel, avec des délais de réponse réduits et une consommation énergétique maîtrisée. Or, le déploiement de modèles lourds sur des plateformes embarquées peut s'avérer difficile, voire irréalisable, lorsque les ressources matérielles sont limitées.

Cette problématique est accentuée dans les architectures embarquées reposant sur des microcontrôleurs à faible consommation d'énergie, tels que l'ESP32, ou sur des dispositifs de calcul en périphérie (*edge computing*). Ces plateformes disposent de capacités mémoire et de calcul restreintes, ce qui impose des compromis entre la complexité du modèle, la précision obtenue et l'efficacité énergétique. Un modèle très performant en environnement de laboratoire peut ainsi devenir impraticable s'il ne respecte pas les contraintes de latence, de consommation ou de capacité mémoire du matériel cible.

Par conséquent, il est essentiel de rechercher un équilibre optimal entre précision de localisation, rapidité d'inférence et efficacité matérielle. Cela peut passer par la conception d'architectures plus légères, l'optimisation des hyperparamètres, la réduction du nombre de paramètres ou encore l'utilisation de techniques de compression de modèles. La prise en compte de ces contraintes dès la phase de conception constitue un facteur déterminant pour assurer la viabilité et l'intégration opérationnelle des systèmes de localisation basés sur l'apprentissage profond en environnement souterrain.

2.6.5 Effet d'évanouissement et échantillonnage spatial

Dans les environnements souterrains, la propagation des ondes radio est fortement affectée par les phénomènes de trajets multiples, générés par les réflexions sur les parois rocheuses, les structures métalliques et les irrégularités géométriques du tunnel. Ces trajets multiples provoquent des fluctuations rapides de l'amplitude et de la phase du signal reçu, connues sous le nom d'évanouissement à petite échelle (*small-scale fading*).

D'un point de vue physique, ces fluctuations spatiales sont liées aux variations de phase entre les composantes *multipath*. Une variation de position de l'ordre d'une fraction de la longueur d'onde modifie les différences de trajet et donc les conditions d'interférence constructive ou destructive. En pratique, la littérature considère souvent qu'un déplacement d'environ une demi-longueur d'onde ($\lambda/2$) constitue une distance caractéristique suffisante pour observer une variation significative de l'état du canal, car il correspond à un déphasage de l'ordre de π entre certaines composantes dominantes du signal[24].

Ainsi, l'adoption d'un espacement spatial proche de $\lambda/2$ lors de la collecte des mesures permet d'échantillonner différentes réalisations du canal radio tout en limitant la redondance entre observations successives. Ce choix vise à améliorer la diversité statistique des données collectées et à mieux représenter la variabilité de l'évanouissement dans l'environnement minier. Dans le cadre de l'apprentissage automatique, cette diversité est importante pour exposer le modèle à plusieurs états du canal et renforcer sa capacité de généralisation face aux variations de propagation observées en conditions réelles.

2.6.6 Erreurs d'étiquetage et précision de la vérité terrain

La disponibilité de données de vérité terrain précises constitue un élément fondamental pour l'entraînement efficace des modèles d'apprentissage supervisé. Dans les systèmes de localisation, les coordonnées de référence associées aux mesures de signal servent de base à l'apprentissage de la relation entre les

caractéristiques radio et la position spatiale. Toute imprécision dans ces étiquettes peut ainsi se répercuter directement sur la qualité du modèle entraîné.

En environnement souterrain, l'obtention d'une vérité terrain fiable représente un défi significatif. L'absence de couverture GPS, la visibilité réduite, la configuration irrégulière des tunnels ainsi que les contraintes opérationnelles compliquent la mesure précise des positions. Même lorsqu'un protocole rigoureux de suivi manuel ou instrumental des coordonnées est mis en place, des erreurs peuvent survenir en raison d'imprécisions de mesure, de décalages mécaniques, d'erreurs humaines ou de difficultés d'alignement spatial. Ces erreurs d'étiquetage introduisent un bruit supplémentaire dans le jeu de données, pouvant altérer le processus d'apprentissage, ralentir la convergence du modèle et dégrader ses performances finales.

De plus, dans le cas de modèles profonds à forte capacité d'apprentissage, la présence d'étiquettes erronées peut conduire à l'ajustement du modèle à des correspondances incorrectes, réduisant ainsi sa capacité de généralisation. Il devient alors essentiel de mettre en place des procédures rigoureuses de validation des données, de calibration des instruments de mesure et, lorsque possible, de vérification croisée des positions enregistrées.

À la lumière de l'ensemble de ces défis — qualité et diversité des données, variabilité environnementale, risques de surapprentissage et contraintes matérielles — le développement d'un système de localisation efficace basé sur l'apprentissage profond nécessite un compromis soigneusement étudié entre la complexité des modèles, la fiabilité des données d'entraînement et les exigences de déploiement en temps réel. Cette réflexion motive l'évaluation comparative de différentes architectures, telles que le MLP, le FCNN et le LSTM, dans des conditions expérimentales cohérentes, afin d'identifier les modèles les plus robustes et les mieux adaptés à la localisation en environnement souterrain.

2.7 Conclusion

Ce chapitre a présenté une analyse approfondie des principales techniques de localisation applicables aux environnements dépourvus de couverture GPS, avec une

attention particulière portée aux contraintes spécifiques des milieux souterrains. Après avoir exposé les limites des approches traditionnelles fondées sur des modèles déterministes, l'étude s'est orientée vers les systèmes de localisation basés sur les signaux radio, notamment ceux exploitant le *Received Signal Strength Indicator* (RSSI) et le *Channel State Information* (CSI). Ces indicateurs constituent aujourd'hui des sources d'information essentielles pour la modélisation de la relation entre le canal radio et la position spatiale.

Les méthodes d'apprentissage automatique classiques, telles que le KNN, le SVM et les forêts aléatoires, ont été examinées en mettant en évidence leurs avantages en termes de simplicité et de robustesse, ainsi que leurs limites face à la complexité et à la variabilité des environnements souterrains. Cette analyse a conduit à l'introduction des approches d'apprentissage profond, incluant le MLP, le FCNN et le LSTM, dont la capacité à apprendre automatiquement des représentations non linéaires à partir de données brutes les rend particulièrement adaptées au traitement des signaux RSSI et CSI de grande dimension.

Le chapitre a également mis en lumière les défis majeurs associés à l'application de l'apprentissage profond à la localisation en milieu minier souterrain. Parmi ceux-ci figurent les contraintes liées à la collecte et à la qualité des données, la variabilité environnementale et les effets de trajets multiples, les risques de surapprentissage et les difficultés de généralisation, ainsi que les limitations matérielles imposées par les plateformes embarquées. Ces éléments soulignent la nécessité d'une conception méthodologique rigoureuse et d'un choix judicieux d'architecture afin d'assurer un compromis optimal entre précision, robustesse et faisabilité opérationnelle.

L'ensemble de ces constats justifie pleinement la mise en place d'une évaluation comparative des architectures profondes dans un cadre expérimental cohérent. L'objectif est d'identifier les modèles les plus performants et les plus robustes pour la localisation en environnement souterrain, en tenant compte à la fois des contraintes physiques du canal radio et des exigences pratiques de déploiement

3. MÉTHODOLOGIE

L'architecture du système de localisation proposé repose sur une intégration cohérente entre la conception du jeu de données expérimental et l'implémentation de modèles d'apprentissage profond adaptés aux contraintes du milieu souterrain. Les mesures exploitées — RSSI et CSI (amplitude et phase) — constituent des caractéristiques radio riche permettant de capturer la complexité de la propagation dans un environnement minier.

Trois architectures de réseaux de neurones ont été retenues afin d'examiner différentes stratégies d'exploitation de ces caractéristiques : le MLP, le FCNN et le LSTM. Ces modèles reposent sur des logiques d'apprentissage distinctes, permettant d'évaluer l'impact de la profondeur, de la capacité de représentation et de l'intégration éventuelle d'une dimension temporelle sur la précision de localisation.

Le MLP est considéré comme modèle de référence en raison de sa structure entièrement connectée et de sa simplicité conceptuelle. Il a été utilisé dans l'étude [25],démontrant sa capacité à modéliser des relations non linéaires entre les paramètres du canal radio et la position spatiale. Dans le cadre de ce travail, l'architecture initiale a été adaptée par ajustement du nombre de couches cachées et du nombre de neurones par couche. Cette optimisation structurelle a permis d'améliorer les performances obtenues, mettant en évidence l'importance d'un réglage architectural adapté aux conditions spécifiques de propagation en tunnel minier.

Le FCNN adopte une architecture plus profonde et plus expressive, offrant une capacité accrue d'abstraction. Il est particulièrement adapté au traitement de vecteurs de grande dimension, tels que les 64 composantes d'amplitude, les 64 composantes de phase du CSI, ainsi que le RSSI. Dans un environnement souterrain caractérisé par des phénomènes complexes de réflexions multiples, de diffractions et d'interactions avec des surfaces métalliques et irrégulières, cette capacité de modélisation non linéaire avancée constitue un avantage significatif. Le FCNN permet

ainsi l'apprentissage de représentations fines du canal radio, contribuant à une amélioration de la précision de localisation.

Le LSTM introduit une dimension temporelle dans le processus d'apprentissage. Contrairement aux architectures purement *feedforward,* il est conçu pour exploiter les dépendances séquentielles entre échantillons successifs. Cette propriété devient pertinente lorsque les mesures sont collectées de manière continue le long d'un corridor, où une corrélation temporelle peut exister entre positions adjacentes. Toutefois, lorsque les données sont indépendantes ou faiblement corrélées dans le temps, l'apport d'un modèle récurrent peut être limité. L'analyse comparative menée dans cette étude permet ainsi d'évaluer de manière rigoureuse la pertinence de l'intégration d'une mémoire temporelle dans le contexte spécifique de la localisation radio en milieu souterrain.

3.1 Dispositif expérimental et configuration matérielle

Le dispositif expérimental illustré dans la Figure 10, repose sur l'utilisation de modules ESP32, constituant une solution Wi-Fi compacte et à faible coût intégrant une interface conforme à la norme IEEE 802.11 b/g/n opérant dans la bande ISM de 2,4 GHz. L'ESP32 présente un intérêt particulier pour les systèmes de localisation basés sur l'apprentissage automatique, car il permet d'accéder simultanément au RSSI et CSI. Le CSI fournit une description fine du canal radio à travers l'amplitude et la phase associées aux sous-porteuses OFDM, contrairement aux dispositifs conventionnels qui se limitent souvent à des indicateurs de puissance globale [26].

Dans cette étude, les ESP32 ont été configurés afin de fonctionner avec une largeur de bande de 40 MHz, ce qui augmente la résolution fréquentielle exploitable dans les données CSI et renforce la richesse des caractéristiques d'entrée utilisées pour la localisation. Le choix de cette plateforme matérielle est motivé par sa simplicité de déploiement, sa disponibilité commerciale, ainsi que sa pertinence applicative pour des environnements contraints tels que les mines, où des solutions portables, robustes et économiques sont généralement privilégiées. Cette approche favorise également la reproductibilité expérimentale et ouvre la voie à une intégration future

dans des systèmes embarqués destinés à la sécurité et au suivi des opérations en milieu souterrain.

En complément des modules ESP32, une unité de contrôle basée sur une le micro-ordinateur à carte unique Raspberry Pi a été utilisée pour superviser la collecte et assurer l'enregistrement structuré des données. La Raspberry Pi agit comme station centrale d'acquisition (data logger), recevant les trames textes contenant les informations RSSI et CSI extraites par le module ESP32 récepteur. Elle permet l'exécution de scripts automatisés destinés à lire, organiser et stocker les mesures sous forme de fichiers exploitables pour le traitement ultérieur. Cette architecture centralisée garantit une acquisition stable et reproductible, tout en facilitant l'intégration systématique d'éléments complémentaires tels que l'horodatage, l'identification des dispositifs et l'étiquetage des positions de référence.

L'utilisation de la Raspberry Pi présente également un intérêt pratique en environnement souterrain en raison de sa compacité, de sa faible consommation énergétique et de sa capacité à fonctionner de manière autonome durant les campagnes de mesures. Elle assure une structuration cohérente des données collectées et réduit les risques d'erreurs humaines lors de l'enregistrement, contribuant ainsi à la fiabilité globale du jeu de données et à la validité scientifique des analyses réalisées par la suite [27].

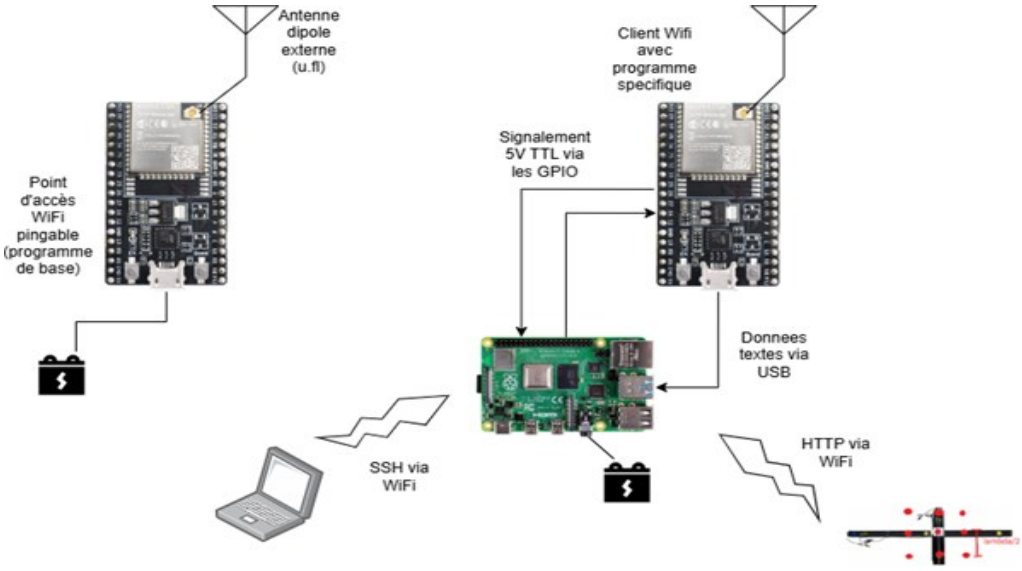

Figure 10
Architecture du système d'acquisition de mesures Wi-Fi : Raspberry Pi et modules ESP (STA/AP)

3.1.1 Configuration de mesure (émetteur–récepteur)

La campagne de mesures repose sur deux modules ESP32 configurés respectivement en mode émetteur (point d'accès) et en mode récepteur (station). L'émetteur est maintenu à une position fixe dans le corridor minier, tandis que le récepteur est déplacé le long d'un ensemble de positions de référence prédéfinies. À chaque position, les mesures RSSI et CSI sont enregistrées, puis associées à des coordonnées spatiales (X, Y) correspondant à la position réelle du récepteur. Les acquisitions sont réalisées dans des conditions de visibilité directe (LOS) et de non-visibilité directe (NLOS), afin de représenter des scénarios de propagation réalistes, marqués par l'atténuation, les réflexions multiples et les trajets multiples caractéristiques des environnements souterrains.

3.1.2 Système de positionnement basé sur des rails linéaires

Afin de positionner précisément le récepteur aux différentes positions de mesure, un système de déplacement bidimensionnel basé sur deux rails motorisés linéaires perpendiculaires a été utilisé, tel qu'illustré dans la Figure 11. Cette configuration

permet de déplacer la plateforme mobile suivant les axes X et Y, assurant ainsi un contrôle précis de la position spatiale du capteur dans le plan horizontal.

Le déplacement le long des rails permet de définir un ensemble de points de mesure régulièrement espacés dans la zone expérimentale. L'espacement entre deux positions successives a été fixé à λ/2, où λ représente la longueur d'onde du signal radio utilisé. Ce choix repose sur le fait que les variations du fading à petite échelle se manifestent sur des distances de l'ordre de la demi-longueur d'onde. Un tel espacement permet ainsi de capturer des états faiblement corrélés du canal radio, augmentant la diversité des observations tout en limitant la redondance des mesures.

Ce type de rails linéaires motorisés a été retenu pour sa grande précision de déplacement, généralement de l'ordre du millimètre, ainsi que pour sa bonne répétabilité positionnelle, garantissant un positionnement fiable et reproductible à chaque point de mesure. Le contrôle du déplacement est assuré par un script Python envoyant des commandes au contrôleur des rails, ce qui permet une synchronisation avec l'acquisition des données ainsi qu'une acquisition plus rapide.

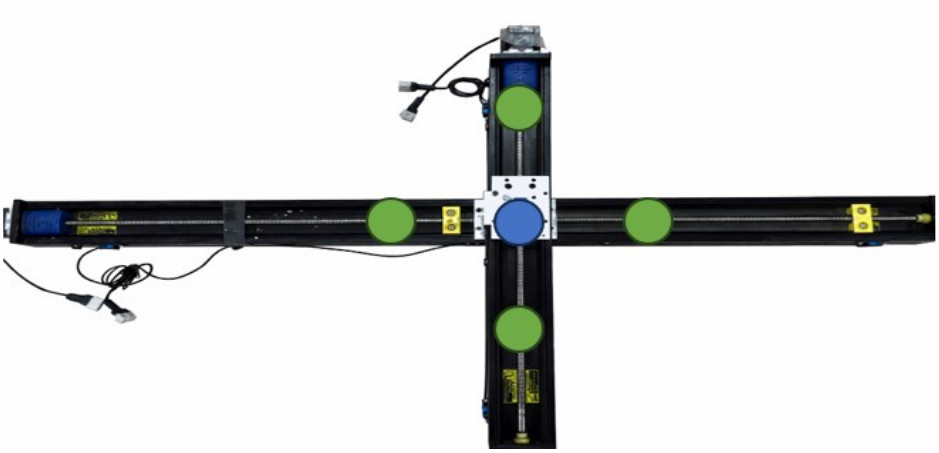

Figure 11
Système de positionnement à rails linéaires et positions du point (bleu) et sous-points (vert) de mesure.

3.2 Jeu de données initial (Section A) – Données de référence

Le premier jeu de données exploité dans cette étude provient de la campagne de mesures initialement présentée dans (2024) [17]. Les données ont été collectées dans

la mine Cité de l'Or (Canada) dans une section de tunnel présentant une géométrie principalement linéaire, incluant des zones LOS et NLOS. Une grille de 303 points spatiaux a été définie le long du corridor, et les mesures sans fil ont été enregistrées à chaque position à l'aide de deux modules ESP32 opérant à 2,4 GHz avec une bande passante de 40 MHz (figure 12). Dans ce premier protocole, l'espacement entre les points de mesure est fixé à 0,5 m, ce qui permet un échantillonnage spatial dense et une observation détaillée des variations locales du canal radio.

Chaque enregistrement contient (i) une valeur RSSI reflétant la puissance reçue, (ii) les informations CSI sous forme de composantes d'amplitude et de phase par sous-porteuse, et (iii) les coordonnées de référence (X, Y) correspondant à la position réelle du récepteur. L'ensemble du jeu de données regroupe 45 164 échantillons annotés. Ce jeu de données constitue la base expérimentale principale utilisée pour l'entraînement initial et l'établissement d'un niveau de performance de référence dans des conditions de tunnel relativement régulières.



Figure 12
Installation du système de mesure dans un milieu souterrain réel

La Figure 13 présente la distribution spatiale des points de mesure uniques (X, Y) correspondant au premier jeu de données (Section A). Cette représentation permet de visualiser la géométrie réelle du corridor minier dans lequel la campagne de mesures a été réalisée. On observe une structure majoritairement linéaire, caractérisée par un alignement dominant le long de l'axe Y, ce qui reflète la configuration essentiellement rectiligne du tunnel étudié. Une légère extension latérale apparaît à certaines positions, traduisant des variations locales de la trajectoire du corridor ou la présence de galeries adjacentes. Cette cartographie confirme que la première section présente une géométrie relativement régulière, offrant ainsi un environnement de référence approprié pour l'évaluation initiale des modèles de localisation avant leur application à des sections plus complexes et davantage marquées par des conditions de propagation NLOS.

Bien que ce premier jeu de données constitue une base expérimentale précieuse pour l'entraînement et l'évaluation initiale des modèles de localisation, certaines limitations doivent être soulignées. Premièrement, la majorité des points de mesure sont situés dans des conditions de visibilité directe (LOS), tandis que les situations de non-visibilité directe (NLOS) demeurent relativement peu représentées. Cette répartition favorise l'apprentissage dans des conditions de propagation relativement simples et ne permet pas d'évaluer pleinement la robustesse du modèle face aux environnements fortement dégradés. Deuxièmement, le protocole d'acquisition repose sur un nombre limité d'échantillons par position, généralement compris entre cinq et dix mesures, ce qui réduit la capacité à capturer l'ensemble des fluctuations temporelles et statistiques du canal radio. Troisièmement, l'espacement fixe de 0,5 m entre les points de mesure n'a pas été défini en fonction des propriétés physiques du canal radio et plus particulièrement du phénomène de fading à petite échelle. À une fréquence de 2,4 GHz, la longueur d'onde est d'environ 12,5 cm et les variations spatiales significatives du canal peuvent apparaître sur des distances de l'ordre de $\lambda/2$. Par conséquent, les effets du fading rapide ainsi que certaines variations spatiales fines du canal n'ont pas été explicitement pris en compte lors de la conception de cette campagne de mesures.

Ces limitations ont motivé la réalisation d'un second jeu de données visant à reproduire des conditions plus représentatives des environnements miniers réels. Celui-ci intègre une proportion plus importante de situations NLOS, une géométrie de tunnel plus complexe ainsi qu'une stratégie d'acquisition mieux adaptée à l'étude des variations spatiales du canal radio. Il constitue ainsi un cadre expérimental plus exigeant permettant d'évaluer la capacité de généralisation et la robustesse des modèles de localisation développés dans ce mémoire.

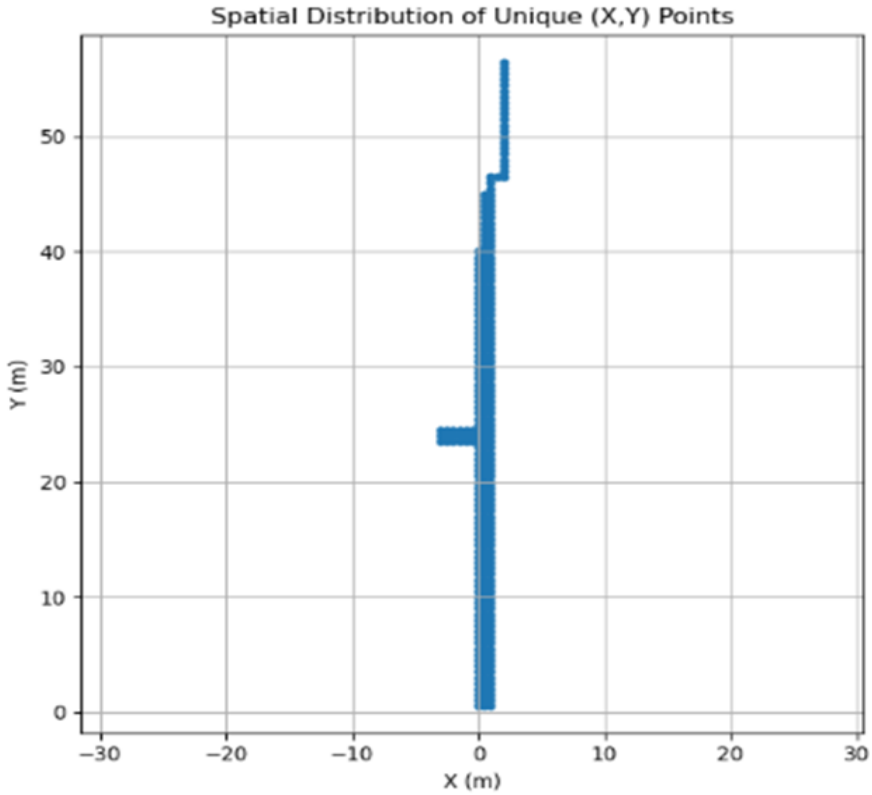

Figure 13
Distribution spatiale des points de mesure uniques (X, Y) le long du tunnel souterrain de la mine.

3.3 Nouveau jeu de données (Section B)

Afin d'évaluer de manière plus rigoureuse la robustesse et la capacité de généralisation des modèles de localisation, un second jeu de données a été acquis dans le cadre du présent mémoire. Cette nouvelle collecte a été réalisée dans la

même mine, mais dans une section différente présentant une géométrie plus complexe, incluant des courbures plus prononcées et des configurations favorisant davantage les conditions NLOS. L'objectif de ce second jeu de données est d'introduire un scénario expérimental plus exigeant, plus proche des conditions opérationnelles réelles, où la propagation est fortement influencée par la non-linéarité géométrique du corridor, l'occultation du signal et les interactions multi-trajets.

Le protocole d'acquisition, dont l'algorigramme est présenté à la Figure 14, conserve la même configuration matérielle que celle de la Section A (ESP32 à 2,4 GHz, bande passante de 40 MHz, puissance d'émission maximale de 30 dBm), ainsi que les mêmes types de données enregistrées (RSSI, amplitude et phase du CSI, coordonnées (X, Y)), afin d'assurer la comparabilité des résultats expérimentaux. Toutefois, plusieurs adaptations méthodologiques ont été introduites afin d'accroître la représentativité du jeu de données et d'en augmenter le niveau de difficulté.

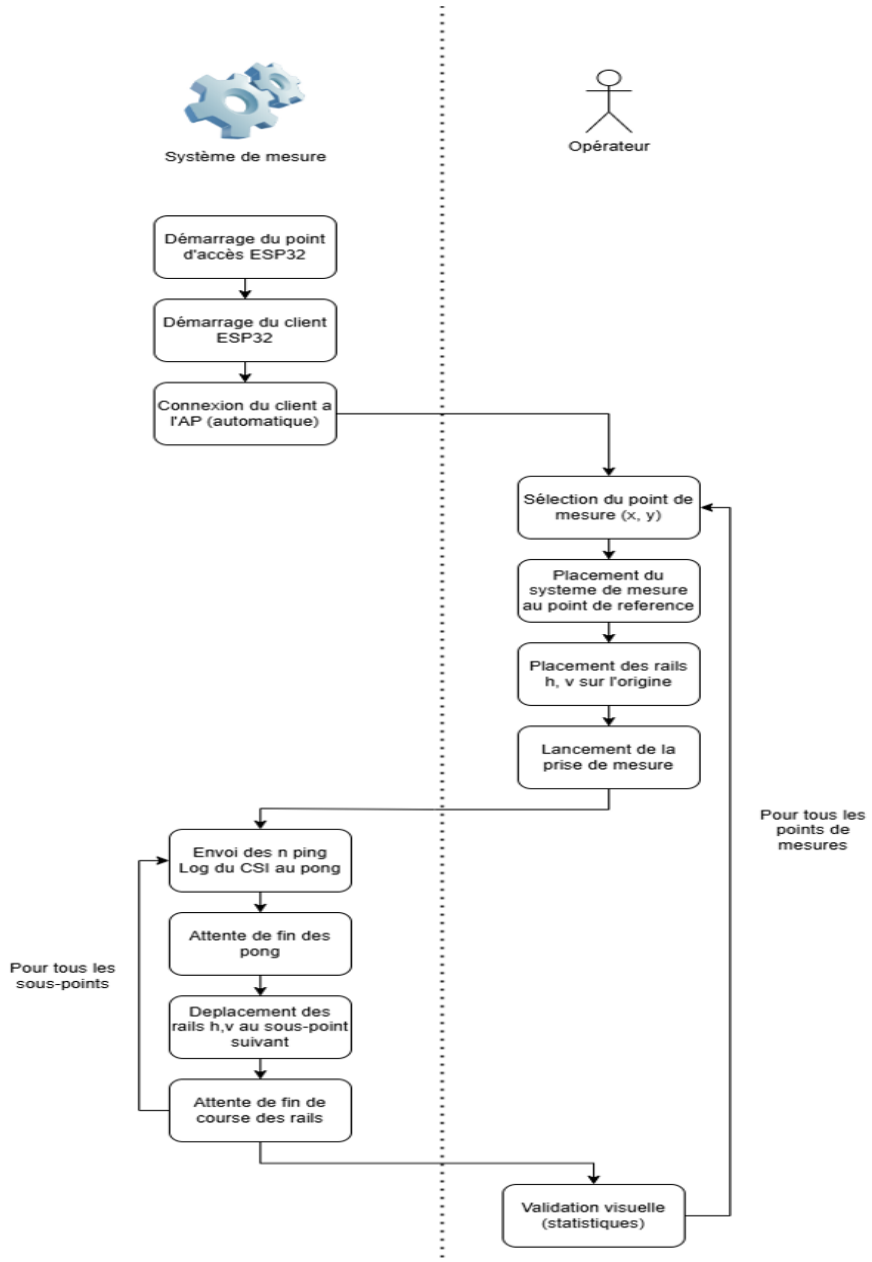

Figure 14
Architecture fonctionnelle de l'acquisition des données de localisation

Premièrement, l'espacement entre les points de mesure est fixé à 1 m, ce qui permet de couvrir une zone plus étendue tout en maintenant une durée d'acquisition

compatible avec un déploiement réaliste sur le terrain. Cet espacement assure également un maillage suffisamment dense et informatif pour les phases d'apprentissage des modèles. Préalablement à l'acquisition des données, un ensemble de points de mesure est matérialisé au sol à l'aide de télémètres laser, de rubans à mesurer et de lasers de construction permettant d'améliorer l'alignement des points sur un terrain irrégulier. Cette étape vise à garantir la cohérence, la précision et la reproductibilité du positionnement tout au long de la campagne de mesures.

La Figure 15 illustre le marquage des points au sol ainsi que l'installation du système d'acquisition des données (au premier plan) et du système de déplacement sur rail (à l'arrière-plan).

Plutôt que de suivre la courbure des tunnels, ce qui nécessiterait la mise en place d'un système de positionnement relatif complexe à déployer sur le terrain, un système de coordonnées cartésiennes a été retenu. Ce choix vise à améliorer la reproductibilité des mesures, à faciliter l'acquisition des données en différents points de l'environnement ainsi que l'implantation des positions de mesure sur le terrain.

Par ailleurs, cette approche simplifie les étapes de post-traitement, puisque les représentations graphiques et les calculs numériques sont généralement réalisés dans un repère cartésien. Elle favorise également la compatibilité avec les outils de simulation susceptibles d'être utilisés dans des travaux futurs, en permettant une correspondance directe entre les coordonnées mesurées et les modèles numériques. L'origine du repère est définie de manière à ce que l'axe y suive la direction principale de la galerie la plus longue, tandis que l'axe x est tracé perpendiculairement à celui-ci, comme illustré à la Figure 15.

Deuxièmement, pour chaque position de référence (X, Y), cinq mesures indépendantes (sous-points dans l'algorigramme) sont enregistrées au lieu d'une seule. Chaque mesure comprend au moins cinquante paquets CSI provenant du trafic entre le point d'accès et le client, générés par des requêtes ping envoyées en boucle par un programme s'exécutant sur le client, cela représentant ainsi un minimum de 250 échantillons CSI par point. Ces cinq acquisitions visent à mieux capturer la

variabilité instantanée du canal radio et les fluctuations dues au fading rapide, aux trajets multiples et au bruit de mesure.

Ces cinq mesures sont réalisées en appliquant un déplacement spatial contrôlé du récepteur avec un espacement égal à λ/2 entre acquisitions, afin d'échantillonner des réalisations distinctes du *fading* à petite échelle. Cette procédure est mise en œuvre à l'aide de deux rails perpendiculaires, permettant des déplacements reproductibles et orthogonaux, et assurant un contrôle précis de la position. Cette stratégie renforce la robustesse statistique de la donnée et permet de représenter plus fidèlement les conditions variables rencontrées dans les environnements souterrains, en particulier en zones NLOS.



Figure 15
Installation du système de mesure dans un milieu souterrain réel.

La Figure 16 illustre la distribution spatiale des points de mesure uniques (X, Y) correspondant au second jeu de données (Section B). Contrairement à la section précédente, la configuration spatiale observée révèle une géométrie nettement plus complexe, caractérisée par une trajectoire courbe, des variations directionnelles successives ainsi que la présence de branches latérales.

Cette distribution reflète fidèlement la structure réelle du corridor minier dans lequel les mesures ont été réalisées. La présence de segments inclinés et de changements de direction indique que la propagation radio dans cette section est soumise à des conditions plus sévères, notamment en raison d'un accroissement des trajets NLOS et d'interactions multichemin plus prononcées. Cette configuration constitue ainsi un scénario expérimental plus exigeant pour les modèles de localisation, permettant d'évaluer leur robustesse face à des relations spatiales non linéaires et à une géométrie d'environnement plus représentative des conditions opérationnelles réelles.

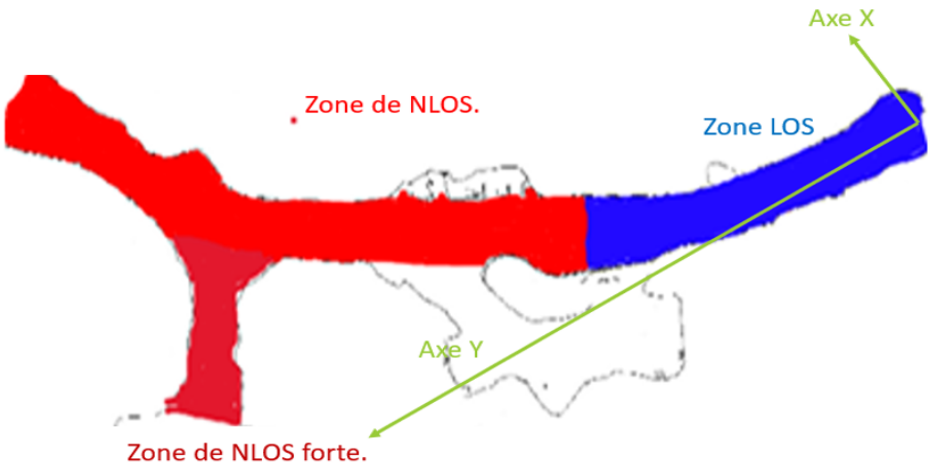

Figure 16
Distribution spatiale des points de mesure dans le tunnel courbe (LOS : bleu, NLOS : rouge)

3.4 Données, structure des échantillons et métadonnées

Dans les deux jeux de données, chaque échantillon est associé à une position de référence et regroupe des caractéristiques radios complémentaires. Les variables d'entrée incluent le RSSI et le CSI, ce dernier étant représenté par des vecteurs d'amplitude et de phase des sous-porteuses. Les sorties associées correspondent

aux coordonnées (X, Y) du récepteur. Lorsque disponible, chaque mesure est horodatée et enrichie par des métadonnées (identifiants des dispositifs, condition LOS/NLOS, etc.), ce qui facilite l'analyse ultérieure, le filtrage et la reproductibilité expérimentale. Ces données sont mises en forme sous la forme d'une trame par un programme exécuté sur l'ESP32, puis transmises via le port série USB. Du côté du système d'acquisition, un enregistreur de données (*data logger)* lit les informations reçues sur le port série et les sauvegarde dans un fichier texte horodaté et identifié selon le point de mesure correspondant. Cette organisation permet leur traitement automatisé lors des étapes subséquentes de la chaîne de traitement.

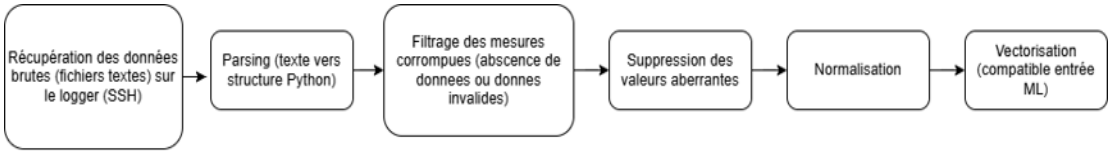

Figure 17
Chaîne de prétraitement des données avant l'apprentissage automatique

La Figure 17 présente la chaîne de prétraitement des données mise en œuvre afin de rendre celles-ci exploitables lors de la phase d'apprentissage. Pour permettre leur traitement hors site, les fichiers texte sont récupérés depuis le système d'acquisition au moyen du protocole SSH. Les trames enregistrées sont ensuite analysées à l'aide d'un programme développé en Python.

Les données considérées comme corrompues, notamment celles présentant une absence totale ou partielle des informations CSI ou ne respectant pas le format attendu, sont automatiquement rejetées. Ces corruptions peuvent avoir plusieurs origines. D'un point de vue fonctionnel, elles sont principalement observées sur les liaisons les plus dégradées, où les conditions de propagation peuvent entraîner des pertes ou des altérations des données. D'un point de vue technique, certaines corruptions ont également été associées à des défaillances de l'alimentation électrique du système, à des erreurs de transmission sur la liaison série ainsi qu'à des dysfonctionnements du mécanisme de signalisation utilisé pour la capture des

données, possiblement accentués par les conditions environnementales du site expérimental.

Par ailleurs, certaines valeurs aberrantes peuvent être identifiées à partir de mesures RSSI ou CSI incompatibles avec le fonctionnement normal du modem. Les échantillons présentant des valeurs de RSSI physiquement impossibles, par exemple supérieures à 0 dBm ou inférieures à −90 dBm, ainsi que ceux dont les coefficients CSI sont nuls, incomplets ou invalides, sont automatiquement rejetés lors de cette étape de prétraitement.

Les amplitudes CSI ont été normalisées par la méthode Min-Max afin de les projeter dans l'intervalle [0,1]. Les phases CSI, exprimées en degrés, ont été normalisées par division par 180 afin d'obtenir des valeurs dans l'intervalle [−1,1]. Enfin, les valeurs RSSI ont été mises à l'échelle par division par 100 pour réduire leur amplitude numérique tout en conservant leur structure relative.

Le CSI représente la réponse fréquentielle détaillée du canal radio en décomposant le signal WiFi en plusieurs sous-porteuses OFDM. Chaque sous-porteuse correspond à une composante fréquentielle distincte du signal et fournit une mesure spécifique de l'état du canal, notamment en amplitude et en phase. Dans le cas présent, le signal est composé de 64 sous-porteuses, dont 52 sont effectivement actives pour la transmission de données, tandis que les 12 restantes sont réservées ou inutilisables (bandes de garde, sous-porteuse DC ou pilotes selon la configuration du système).

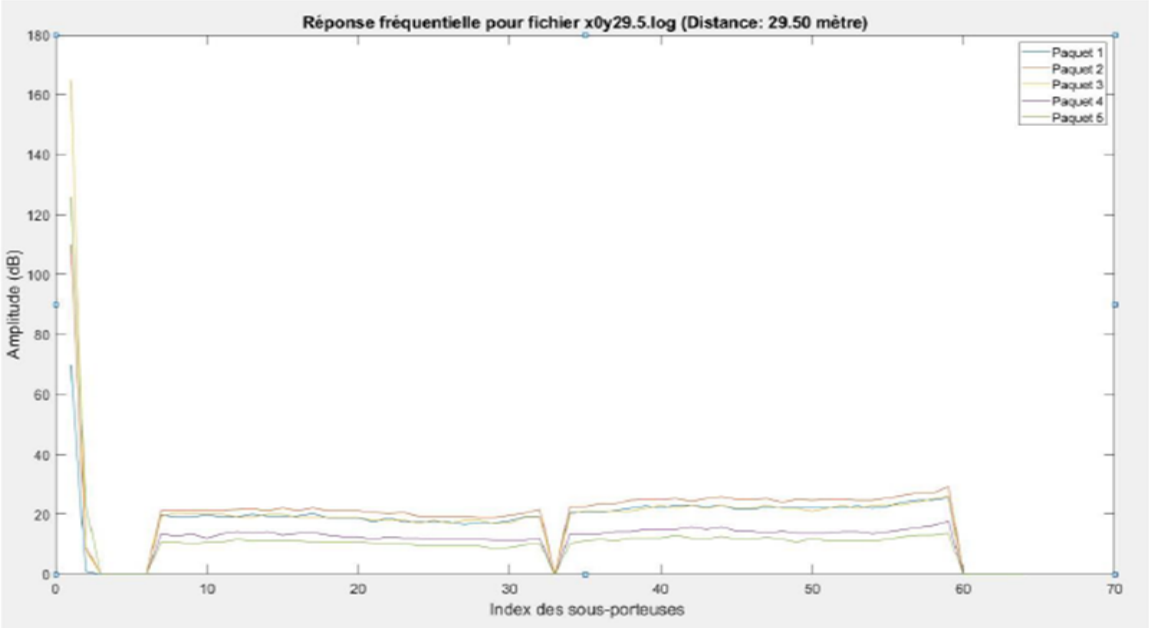

Figure 18
Visualisation des sous-porteuses du signal CSI

La

Figure 18 illustre l'amplitude mesurée sur ces sous-porteuses pour cinq paquets successifs capturés au même point de mesure. On observe que, bien que les mesures soient réalisées à une position fixe, les amplitudes varient légèrement d'un paquet à l'autre, ce qui reflète la variabilité instantanée du canal radio due aux effets de fading, aux multi-trajets et aux perturbations locales de propagation. Cette représentation met en évidence la richesse informationnelle du CSI par rapport au RSSI, puisque chaque sous-porteuse apporte une information fréquentielle fine sur le canal, exploitable pour la localisation et l'apprentissage automatique.

Les échantillons normalisés sont ensuite convertis en vecteurs de caractéristiques, puis regroupés dans des structures de données compatibles avec la bibliothèque de réseaux de neurones utilisée pour l'apprentissage.

3.5 Stratégie d'évaluation et analyse de la généralisation

Une stratégie d'évaluation croisée est adoptée afin de quantifier la performance des modèles dans des conditions environnementales distinctes. Les modèles d'apprentissage automatique sont évalués sur deux jeux de données correspondant à deux sections minières présentant des caractéristiques de propagation différentes, afin d'analyser : (i) leur précision dans une section relativement régulière et majoritairement en visibilité directe (Section A), (ii) leur robustesse dans une section géométriquement plus complexe et davantage dominée par des conditions NLOS (Section B), et (iii) leur capacité de généralisation face à un changement de géométrie, de corridor et de conditions de propagation.

Cette démarche permet de déterminer si les modèles apprennent uniquement des motifs spécifiques à une géométrie donnée ou s'ils capturent des caractéristiques plus générales du canal radio en milieu souterrain. L'évaluation dans un environnement distinct, plus irrégulier et plus fortement affecté par les phénomènes de multi-trajets, constitue ainsi un indicateur important de l'applicabilité pratique du système dans des conditions réelles de déploiement minier.

En parallèle de cette analyse de généralisation, une étude spécifique est menée sur la sensibilité des modèles à la représentation des données du canal. Chaque point de mesure est associé à cinq acquisitions successives, et chaque acquisition contient N échantillons CSI, correspondant à différentes réalisations instantanées du canal radio. Lors de l'inférence, chaque échantillon est traité individuellement par le modèle, produisant ainsi un ensemble de prédictions pour une même position physique.

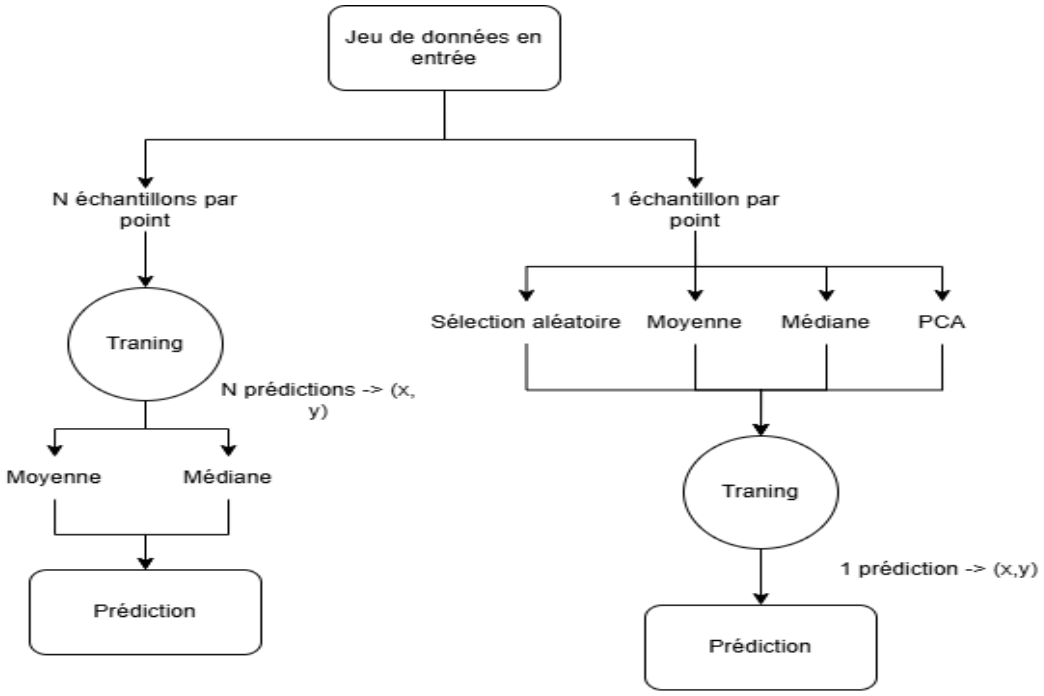

Figure 19
Schéma comparatif des approches d'agrégation des données et des prédictions pour la localisation basée sur CSI.

Cette configuration soulève la question de la stratégie d'agrégation la plus appropriée. Ainsi deux approches sont étudiées (Figure 19). La première consiste à agréger les données directement à l'entrée du modèle, en appliquant une opération statistique (moyenne ou médiane) sur les N échantillons CSI avant traitement. Cette approche réduit la variabilité instantanée du signal, mais peut potentiellement atténuer certaines informations fines liées à l'évanouissement à petite échelle. La seconde approche consiste à conserver l'ensemble des échantillons individuels comme entrées indépendantes, puis à agréger uniquement les prédictions produites en sortie du réseau. Cette stratégie permet de préserver l'information complète du canal tout au long du processus d'apprentissage et d'inférence.

L'analyse comparative de ces deux approches, ainsi que des différentes méthodes d'agrégation en sortie (moyenne ou médiane), permettra d'évaluer leur impact sur la précision, la stabilité et la robustesse des modèles de localisation, et d'identifier la

stratégie la plus adaptée aux variations rapides du canal radio en environnement minier souterrain.

3.6 Modèles et architectures

Cette section présente la conception, l'implémentation et l'optimisation de trois architectures distinctes d'apprentissage profond : le FCNN, le MLP et le LSTM. Ces modèles ont pour objectif d'apprendre la relation complexe et non linéaire entre les caractéristiques des signaux sans fil, notamment le RSSI et le CSI, et les coordonnées spatiales X et Y du récepteur dans un contexte de localisation souterraine. Dans les environnements miniers, cette relation est particulièrement difficile à modéliser en raison des phénomènes de propagation multiples, des réflexions sur les parois, des atténuations variables et des occultations du signal. L'utilisation de modèles d'apprentissage profond se justifie donc par leur capacité à capturer des interactions non linéaires de haute dimension entre les variables d'entrée.

Afin d'assurer une comparaison équitable entre les approches étudiées, tous les modèles partagent la même structure d'entrée et de sortie. Chaque échantillon d'entrée est représenté par un vecteur de 129 caractéristiques dérivées des mesures normalisées de RSSI et de CSI. Les sorties correspondent à deux valeurs continues représentant les coordonnées spatiales estimées X et Y, ce qui définit le problème comme une tâche de régression multivariée.

Pour le modèle MLP, plusieurs configurations ont été explorées en faisant varier le nombre de couches cachées, le nombre de neurones par couche ainsi que certains paramètres d'entraînement. Cette phase d'optimisation a permis d'identifier une architecture offrant des performances supérieures à celles rapportées dans [25], mettant en évidence l'importance d'un réglage architectural adapté aux conditions de propagation spécifiques du milieu souterrain.

Dans le cas des modèles FCNN et LSTM, différentes structures ont également été testées et comparées de manière systématique comme résume dans le tableau 1. Pour le FCNN, l'objectif principal était d'augmenter la capacité de représentation du

réseau afin de mieux modéliser les interactions complexes entre les caractéristiques du canal radio.

Pour le LSTM, l'objectif était d'évaluer sa capacité à exploiter les dépendances séquentielles entre mesures successives.

Les architectures finales ont été retenues selon leur précision, leur stabilité d'apprentissage et leur capacité de généralisation. Cette comparaison permet d'identifier l'architecture la plus adaptée à la modélisation du canal radio en environnement souterrain. Les différents types de réseaux de neurones partagent une configuration commune afin de garantir une comparaison cohérente de leurs performances. Cette configuration est illustrée à la Figure 20.

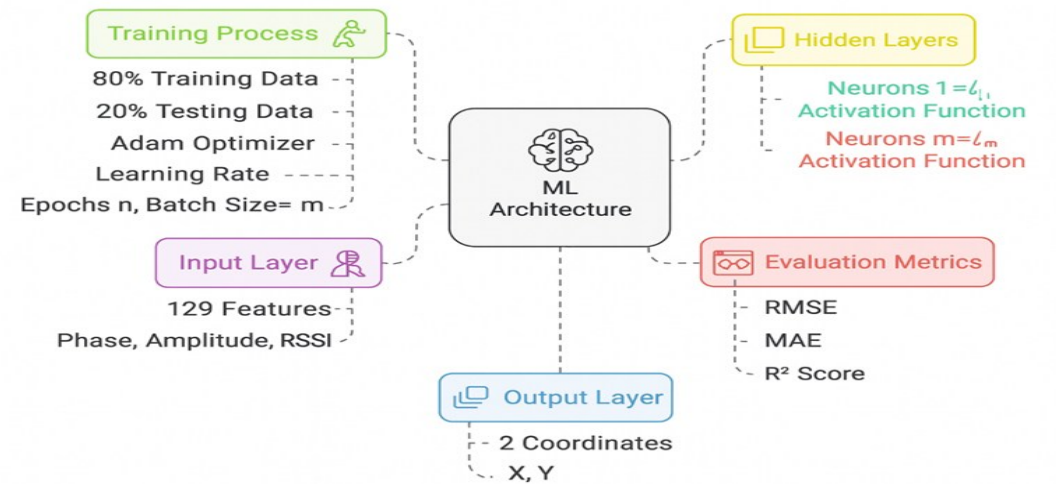

Figure 20
Architecture des réseaux neuronaux pour la localisation

3.6.1 Architecture FCNN (*Fully Convolutional Neural Network*)

Le modèle FCNN a été conçu afin de modéliser les relations non linéaires complexes entre les caractéristiques radios extraits du canal et les coordonnées spatiales associées. Contrairement aux architectures convolutionnelles ou récurrentes, le FCNN repose sur une structure entièrement connectée, dans laquelle chaque neurone d'une couche est relié à l'ensemble des neurones de la couche suivante.

Cette architecture est particulièrement adaptée aux problèmes de régression sur des données vectorielles, où l'objectif consiste à apprendre une correspondance directe entre un ensemble de caractéristiques d'entrée et des variables continues de sortie.

Dans cette étude, le vecteur d'entrée est constitué de 129 caractéristiques, correspondant à 64 amplitudes CSI, 64 phases CSI et 1 valeur RSSI. Cette représentation combine des informations complémentaires sur l'état du canal radio : le CSI fournit une description fréquentielle détaillée de la propagation, tandis que le RSSI apporte une mesure globale de la puissance reçue. L'intégration conjointe de ces caractéristiques permet de capturer à la fois les variations fines du canal et les tendances globales d'atténuation.

L'architecture proposée comprend trois couches cachées successives composées respectivement de 512, 256 et 128 neurones correspondant à la configuration présentant le plus bas RMSE (voir tableau 1).

Tableau 1
Comparaison des performances du modèle FCNN selon différentes configurations architecturales des couches cachées.

	512-256-128	256-128-64	128-64-32
RMSE X	1.8859	2.1037	3.4453
RMSE Y	2.1597	2.6358	6.8102

Chaque couche utilise une fonction d'activation ReLU (Rectified Linear Unit) afin d'introduire la non-linéarité nécessaire à l'apprentissage de relations complexes entre les variables d'entrée. Afin de stabiliser l'apprentissage et d'accélérer la convergence, chaque couche est suivie d'une étape de Batch Normalization, permettant de normaliser la distribution interne des activations. Un mécanisme de régularisation de type Dropout, avec un taux de 0,3, est également appliqué afin de limiter le risque de surapprentissage et d'améliorer la capacité de généralisation du modèle

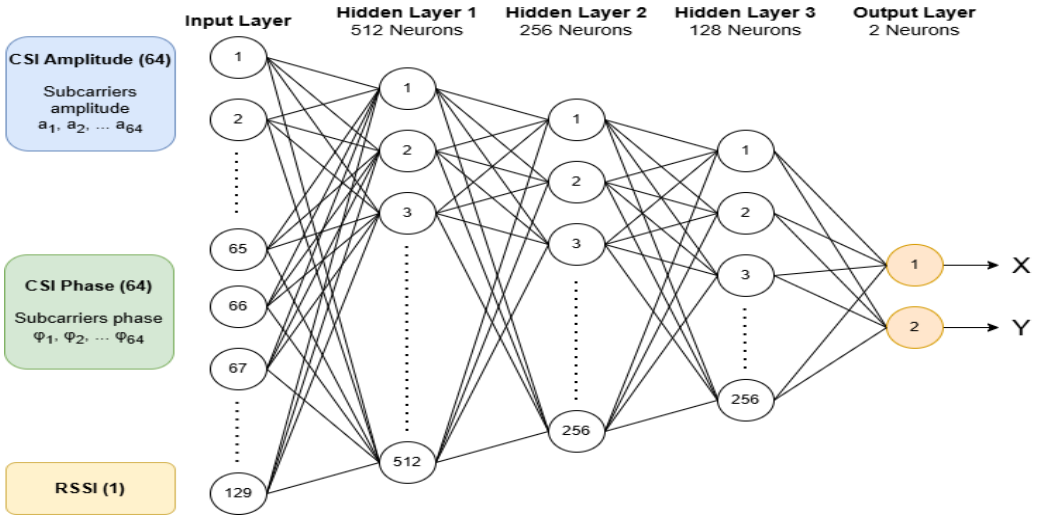

Figure 21
Architecture du réseau neuronal FCNN optimisé proposé.

La couche finale est une couche dense linéaire composée de deux neurones, correspondant aux coordonnées spatiales estimées X et Y. Cette configuration permet de traiter le problème de localisation comme une tâche de régression continue, dans laquelle le réseau apprend directement la fonction de transformation reliant les signatures radio aux positions spatiales.

L'entraînement du modèle est réalisé à l'aide de l'optimiseur Adam, avec un taux d'apprentissage fixé à 0,001, choisi pour sa stabilité et sa capacité d'adaptation automatique du pas de gradient. La fonction de perte utilisée est l'erreur quadratique moyenne (*Mean Squared Error*, MSE), particulièrement adaptée aux problèmes de régression continue. Le réseau est entraîné pendant 100 époques, avec une taille de lot ajustable selon les contraintes de calcul et les performances observées lors des expérimentations.

Les résultats préliminaires la conception d'une architecture optimisée montrent que la performance du modèle est fortement dépendante de sa capacité, définie ici par le nombre de neurones par couche cachée. Une réduction progressive de la taille du réseau entraîne une dégradation significative des performances, avec une augmentation du RMSE sur les deux axes, particulièrement marquée pour l'axe Y.

Cela confirme que la relation entre les signatures CSI et la position est hautement non linéaire et nécessite une capacité de modélisation élevée. Un réseau plus large permet de mieux approximer ces relations complexes, tandis qu'une architecture plus compacte conduit à une sous-capacité et à une perte d'information importante.

On observe que l'erreur de localisation est systématiquement plus élevée sur l'axe Y que sur l'axe X. Ce comportement peut s'expliquer par l'anisotropie du canal radio en environnement souterrain. Les déplacements selon l'axe X entraînent des variations plus progressives et mieux structurées des trajets dominants entre l'émetteur et le récepteur, tandis que les déplacements selon l'axe Y modifient de manière plus brutale la géométrie des multi-trajets. Cette sensibilité accrue aux réflexions et aux obstructions latérales rend la relation entre les signatures CSI et la position plus non linéaire et moins stable sur l'axe Y, ce qui explique la dégradation des performances observée.

Cependant, contrairement aux architectures récurrentes comme le LSTM, le FCNN ne modélise pas explicitement les dépendances séquentielles entre observations successives. Son efficacité dépend donc principalement de la qualité et de la richesse des caractéristiques d'entrée. Cette limitation justifie l'évaluation comparative avec d'autres architectures, afin de déterminer la structure la plus adaptée aux propriétés physiques du canal radio souterrain.

3.6.2 Architecture MLP (*Perceptron multicouche*)

Le modèle MLP est utilisé dans cette étude comme architecture de référence en raison de sa simplicité conceptuelle, de sa robustesse et de son efficacité démontrée dans de nombreuses tâches de régression non linéaire. Il constitue l'une des formes les plus fondamentales de réseaux de neurones artificiels entièrement connectés et sert fréquemment de base comparative pour évaluer la pertinence d'architectures plus complexes. Dans le contexte de la localisation radio en milieu souterrain, le MLP permet d'estimer directement la fonction de transformation reliant les caractéristiques du signal sans fil aux coordonnées spatiales du récepteur.

L’architecture adoptée prend en entrée un vecteur de 129 caractéristiques correspondant aux données normalisées issues des mesures RSSI et CSI. Ces variables décrivent l’état instantané du canal radio et contiennent des informations pertinentes sur les phénomènes de propagation tels que l’atténuation, les réflexions multiples et les variations de phase. Le réseau comporte plusieurs couches cachées entièrement connectées destinées à apprendre progressivement des représentations abstraites des données. La première couche dense comprend 256 neurones avec une fonction d’activation *ReLU,* suivie d’une seconde couche de 128 neurones, puis d’une troisième couche de 64 neurones, utilisant la même fonction d’activation non linéaire. Cette structure hiérarchique permet au modèle d’extraire et de combiner des relations non linéaires entre les caractéristiques d’entrée.

La couche de sortie est une couche dense linéaire composée de deux neurones correspondant aux coordonnées spatiales estimées X et Y. Cette formulation permet de traiter le problème comme une tâche de régression continue, dans laquelle le réseau apprend à approximer directement la position du récepteur à partir des caractéristiques du canal radio.

L’entraînement du modèle repose sur les mêmes paramètres que ceux utilisés pour le FCNN afin d’assurer une comparaison équitable entre architectures. Ainsi, l’optimiseur Adam est utilisé avec un taux d’apprentissage fixé à 0,001, et la fonction de perte choisie est l’erreur quadratique moyenne (MSE), adaptée aux problèmes de régression. Le nombre d’époques et la taille de lot sont également maintenus identiques, ce qui garantit que les différences de performance observées proviennent uniquement de la structure du modèle et non des conditions d’entraînement.

L’un des principaux avantages du MLP réside dans sa simplicité d’implémentation et sa capacité à modéliser efficacement des relations non linéaires lorsque la complexité des données reste modérée. De plus, son nombre relativement limité de paramètres le rend moins sujet au surapprentissage dans les cas où la taille du jeu de données est restreinte. Toutefois, cette architecture présente certaines limitations structurelles. Contrairement aux réseaux convolutionnels ou récurrents, le MLP ne possède aucun

mécanisme intrinsèque permettant d'exploiter les dépendances spatiales ou temporelles présentes dans les données. Il traite chaque caractéristique indépendamment et ne tient pas compte de la structure interne des vecteurs d'entrée, ce qui peut réduire ses performances lorsque l'information pertinente est distribuée de manière structurée dans les dimensions du signal.

Malgré ces limitations, le MLP constitue une référence essentielle pour l'analyse comparative, car il permet d'évaluer le gain réel apporté par des architectures plus sophistiquées dans la modélisation du canal radio en environnement souterrain.

3.6.3 Architecture LSTM (*Long Short-Term Memory*)

Les réseaux LSTM constituent une catégorie particulière de réseaux de neurones récurrents conçus pour modéliser des dépendances séquentielles et temporelles dans les données. Contrairement aux architectures *feedforward* classiques, les LSTM possèdent des mécanismes internes de mémoire leur permettant de conserver et d'exploiter l'information pertinente sur plusieurs instants successifs. Cette propriété est particulièrement intéressante dans le contexte de la localisation radio, où les caractéristiques du canal peuvent présenter des variations corrélées dans le temps ou entre positions spatialement proches, notamment en raison des effets de multi-trajets, de fading et de perturbations environnementales.

Dans cette étude, le modèle LSTM est évalué afin de vérifier dans quelle mesure les dépendances séquentielles présentes dans les mesures radio peuvent être exploitées pour améliorer la précision de localisation. Bien que les données collectées correspondent à des positions spatiales successives plutôt qu'à une séquence temporelle classique, l'espacement régulier entre les points de mesure (λ/2) introduit une continuité spatiale susceptible de conserver une certaine corrélation locale du canal. Cette structuration spatiale peut être assimilée à une séquence pseudo-temporelle, dans laquelle chaque point de mesure représente un état successif du canal radio. L'objectif est donc d'évaluer si cette structure séquentielle implicite peut être capturée par le LSTM et contribuer à une meilleure modélisation des variations locales du signal dans l'environnement souterrain.

Pour permettre cette exploitation séquentielle, les données d'entrée sont restructurées sous forme de séquences tridimensionnelles afin d'être compatibles avec le fonctionnement des cellules LSTM. Chaque échantillon est ainsi représenté sous la forme d'une séquence définie par un nombre de pas successifs et un ensemble de caractéristiques associées à chaque pas. Cette représentation permet au modèle d'exploiter la continuité locale du canal et d'apprendre des motifs évolutifs qui pourraient ne pas être directement capturés par des architectures statiques.

L'architecture proposée commence par une première couche LSTM composée de 64 unités utilisant une fonction d'activation *tanh*, avec l'option *return_sequences* activée afin de transmettre l'ensemble de la séquence à la couche suivante. Une seconde couche LSTM de 128 unités est ensuite appliquée, permettant une modélisation plus profonde des dépendances séquentielles et produisant une représentation compacte du signal. Cette sortie est suivie d'une étape de normalisation (*Batch Normalization*) visant à stabiliser l'apprentissage et à accélérer la convergence, puis d'un mécanisme de régularisation (Dropout) avec un taux de 30 %, destiné à réduire le risque de surapprentissage. Une couche dense avec activation *ReLU* est ensuite utilisée pour transformer la représentation extraite en un espace adapté à la tâche de régression. Enfin, la couche de sortie est constituée d'une couche dense linéaire comprenant deux neurones correspondant aux coordonnées spatiales estimées X et Y.

L'entraînement du modèle est réalisé à l'aide de l'optimiseur Adam avec un taux d'apprentissage de 0,001, et la fonction de perte utilisée est l'erreur quadratique moyenne (MSE), adaptée aux problèmes de régression continue. Le réseau est entraîné pendant 100 époques, avec une taille de lot ajustable en fonction des contraintes de calcul et des performances observées lors des essais expérimentaux. L'utilisation des mêmes paramètres d'entraînement que pour les modèles FCNN et MLP garantit une comparaison équitable entre les architectures.

L'un des principaux avantages du modèle LSTM réside dans sa capacité à modéliser explicitement les variations séquentielles du signal, ce qui peut être particulièrement bénéfique dans les environnements où les caractéristiques radio évoluent de manière

corrélée, comme c'est souvent le cas dans les tunnels miniers dominés par des conditions NLOS. Toutefois, cette architecture présente également certaines limitations. Sa complexité structurelle entraîne un coût computationnel plus élevé et un temps d'entraînement plus long que les architectures statiques. De plus, lorsque les données ne présentent pas de dépendances séquentielles suffisamment exploitables, les performances du LSTM peuvent ne pas surpasser celles de modèles plus simples.

Malgré ces contraintes, l'intégration du LSTM dans l'analyse comparative permet d'évaluer l'apport réel de la modélisation séquentielle dans la tâche de localisation et d'identifier dans quelles conditions cette architecture peut constituer une alternative pertinente aux approches *feedforward* classiques.

3.7 Métriques de performance pour l'évaluation des modèles

Afin d'évaluer de manière rigoureuse et objective les performances des modèles de réseaux neuronaux développés dans cette étude, deux métriques d'erreur complémentaires ont été utilisées, à savoir la racine de l'erreur quadratique moyenne, RMSE et MAE. Ces indicateurs sont largement employés dans les tâches d'apprentissage automatique fondées sur la régression, car ils permettent de quantifier avec précision l'écart entre les valeurs prédites par le modèle et les valeurs réelles de référence.

Le RMSE mesure la magnitude globale de l'erreur en accordant un poids plus important aux écarts élevés, ce qui le rend particulièrement sensible aux erreurs importantes de prédiction. Cette propriété est pertinente dans le contexte de la localisation, où de grandes erreurs spatiales peuvent avoir un impact significatif sur la fiabilité du système. En revanche, le MAE correspond à la moyenne des écarts absolus entre les valeurs estimées et les valeurs réelles, fournissant ainsi une mesure plus robuste de l'erreur moyenne sans amplification excessive des valeurs extrêmes.

L'utilisation conjointe de ces deux métriques permet d'obtenir une évaluation plus complète du comportement des modèles. Tandis que le RMSE reflète la dispersion globale des erreurs et pénalise davantage les prédictions imprécises, le MAE fournit

une estimation plus directe de l'erreur moyenne réelle. Ensemble, ces mesures offrent une vision complémentaire de la performance des architectures étudiées et permettent de comparer de manière fiable leur capacité à estimer les coordonnées spatiales à partir des caractéristiques du signal radio.

3.7.1 Erreur quadratique moyenne racine (RMSE)

La racine de l'erreur quadratique moyenne, communément appelée RMSE (*Root Mean Square Error*), constitue une métrique fondamentale pour l'évaluation des performances des modèles de régression. Elle mesure l'écart global entre les valeurs prédites par le modèle et les valeurs réelles observées, en calculant la racine carrée de la moyenne des carrés des différences entre ces deux quantités[28].

Elle s'exprime mathématiquement comme suit:

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \qquad (17)$$

Où n représente le nombre total d'échantillons, y_i désigne la valeur réelle observée pour l'échantillon i, et $\hat{y}_i$ correspond à la valeur prédite par le modèle pour ce même échantillon.

Le RMSE présente la particularité d'être particulièrement sensible aux erreurs de grande amplitude. En effet, l'élévation au carré des résidus accentue l'influence des écarts importants entre prédictions et observations, ce qui conduit cette métrique à pénaliser plus fortement les modèles produisant des erreurs significatives. Cette propriété est particulièrement pertinente dans le contexte de la localisation spatiale, où de grandes erreurs de position peuvent compromettre la fiabilité globale du système. Ainsi, le RMSE constitue un indicateur essentiel pour évaluer la précision globale d'un modèle et pour comparer différentes architectures en tenant compte de leur capacité à limiter les erreurs les plus critiques.

3.7.2 Erreur absolue moyenne (MAE)

L'erreur absolue moyenne, ou MAE, constitue une métrique fondamentale pour l'évaluation des performances des modèles de régression. Elle mesure la moyenne des écarts absolus entre les valeurs prédites par le modèle et les valeurs réellement observées[29].

Elle peut être exprimée mathématiquement comme suit :

$$MAE = \frac{1}{n}\sum_{i=1}^{n} | y_i - \hat{y}_i | \quad (18)$$

Où n représente le nombre total d'échantillons, y_i correspond à la valeur réelle observée pour l'échantillon i, et $\hat{y}_i$ désigne la valeur prédite par le modèle.

Contrairement au RMSE, la MAE traite toutes les erreurs de manière linéaire, ce qui signifie que chaque écart contribue proportionnellement à la valeur finale de la métrique. Cette propriété empêche les erreurs de grande amplitude d'exercer une influence excessive sur l'évaluation globale, rendant ainsi la MAE plus robuste face aux valeurs aberrantes ou aux prédictions fortement erronées. Elle est également plus intuitive à interpréter, puisqu'elle s'exprime dans la même unité que la variable de sortie, ce qui permet d'appréhender directement l'erreur moyenne commise par le modèle en termes physiques, notamment en mètres dans le cas d'une localisation spatiale.

Bien que la MAE ne mette pas autant en évidence les déviations extrêmes que le RMSE, elle fournit une estimation plus représentative de l'erreur typique observée sur l'ensemble du jeu de données. Ainsi, l'utilisation conjointe du MAE et du RMSE permet d'obtenir une analyse plus complète des performances : tandis que le RMSE souligne l'impact des grandes erreurs, la MAE décrit la précision moyenne réelle des prédictions. Cette complémentarité rend ces deux métriques particulièrement adaptées à l'évaluation comparative de modèles de localisation en environnement souterrain.

3.7.3 Coefficient de détermination (R^2)

Le coefficient de détermination, noté R^2, constitue une métrique statistique largement utilisée pour évaluer les performances des modèles de régression. Il mesure la proportion de la variance des données observées qui est expliquée par les prédictions du modèle. Autrement dit, il quantifie la capacité du modèle à reproduire la dispersion des valeurs réelles autour de leur moyenne[30].

Cette métrique peut être exprimée mathématiquement comme suit :

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \quad (19)$$

Où y_i représente les valeurs réelles observées, $\hat{y}_i$ les valeurs prédites par le modèle, $\bar{y}$ la moyenne des valeurs réelles, et n le nombre total d'échantillons.

Une valeur de R^2 proche de 1 indique que le modèle explique une grande partie de la variance des données, ce qui traduit une forte capacité prédictive et un ajustement efficace aux observations expérimentales. À l'inverse, une valeur proche de 0 suggère que le modèle n'explique qu'une faible portion de la variabilité des données, ses prédictions n'étant pas significativement meilleures qu'une estimation basée uniquement sur la moyenne des valeurs réelles. Il est également possible d'obtenir des valeurs négatives, ce qui se produit lorsque le modèle présente des performances inférieures à cette estimation de référence, révélant ainsi une capacité de modélisation insuffisante.

Cette métrique présente un intérêt particulier car elle ne se limite pas à quantifier l'ampleur des erreurs de prédiction, mais évalue également la qualité globale de l'ajustement du modèle à la distribution statistique des données. Elle constitue ainsi un indicateur complémentaire au RMSE et au MAE, permettant d'obtenir une vision plus complète des performances des architectures étudiées. Dans le contexte de la localisation souterraine, l'analyse du R^2 permet notamment de vérifier si le modèle

parvient à capturer correctement les variations spatiales réelles du signal radio, ce qui est essentiel pour garantir la fiabilité des estimations de position.

3.7.4 Fonction de répartition cumulative (CDF) des erreurs

Bien que les métriques classiques telles que le RMSE, le MAE et le coefficient de détermination R^2 fournissent des indicateurs quantitatifs synthétiques de la précision des modèles, elles ne permettent pas de décrire la distribution complète des erreurs de prédiction. Ces mesures scalaires résument l'information sous forme de valeurs moyennes ou globales, mais ne renseignent pas sur la variabilité des erreurs ni sur la proportion d'estimations satisfaisant un certain niveau de précision. Afin de compléter cette analyse, la fonction de répartition cumulative (*Cumulative Distribution Function,* CDF) des erreurs de localisation est utilisée comme outil d'évaluation supplémentaire.

La CDF représente la probabilité cumulative qu'une erreur de prédiction soit inférieure ou égale à un seuil donné. Elle permet ainsi de visualiser directement la proportion de prédictions respectant une précision spécifique, offrant une interprétation intuitive et informative des performances globales du modèle. Graphiquement, la courbe CDF exprime le pourcentage cumulé d'échantillons en fonction de l'erreur de localisation correspondante, généralement exprimée en unités physiques telles que les mètres.

L'analyse de cette courbe permet d'extraire des indicateurs particulièrement pertinents pour les applications de localisation. Par exemple, il devient possible de déterminer le pourcentage de prédictions dont l'erreur est inférieure à un seuil donné, ce qui permet d'énoncer des résultats du type : « 90 % des estimations présentent une erreur inférieure à 2 mètres ». Ce type d'information est essentiel dans les systèmes de positionnement réels, où les exigences de performance sont souvent définies en termes de seuils de précision maximaux admissibles plutôt qu'en fonction de simples valeurs moyennes.

Par ailleurs, la CDF offre une vision globale du comportement du modèle sur l'ensemble du jeu de données, permettant d'identifier la dispersion des erreurs, la présence éventuelle de valeurs extrêmes et la stabilité des performances. Elle constitue ainsi un complément indispensable aux métriques statistiques

traditionnelles, en fournissant une analyse plus complète et plus représentative de la fiabilité du système de localisation. Dans le contexte de cette étude, l'utilisation de la CDF permet donc d'évaluer non seulement la précision moyenne des modèles, mais également leur robustesse et leur capacité à maintenir un niveau de performance satisfaisant dans différentes conditions de propagation.

3.8 Conclusion

Ce chapitre a présenté de manière détaillée la conception globale du système expérimental et méthodologique développé pour l'entraînement et l'évaluation de modèles d'apprentissage automatique appliqués à la localisation en environnement souterrain à partir de données de signaux sans fil. Il a tout d'abord décrit la constitution du jeu de données principal, comprenant 45 164 mesures collectées dans un tunnel minier réel sous des conditions de LOS et de NLOS à l'aide de modules ESP32. Les données acquises, constituées de mesures RSSI, d'informations CSI et de coordonnées spatiales de référence, reflètent fidèlement la complexité physique des environnements souterrains, caractérisés par des phénomènes de multi-trajets, d'atténuation variable et d'interactions multiples avec les parois et obstacles. Ce jeu de données constitue ainsi une base expérimentale essentielle pour l'apprentissage et la validation de modèles prédictifs de localisation.

Le chapitre a ensuite présenté les architectures d'apprentissage profond retenues pour cette étude, à savoir le MLP, le FCNN et le LSTM, chacune reposant sur une approche de modélisation différente. Ces modèles ont été conçus afin d'estimer directement les coordonnées spatiales du récepteur à partir des caractéristiques du signal radio. Une attention particulière a été portée à la conception architecturale, incluant le choix du nombre de couches, des fonctions d'activation, des mécanismes de régularisation et des paramètres d'optimisation, afin d'adapter les réseaux aux contraintes spécifiques du canal radio en milieu souterrain. Tous les modèles ont été entraînés et évalués selon un protocole expérimental cohérent reposant sur un pipeline de prétraitement identique et sur un ensemble commun de métriques de

performance, notamment le RMSE, le MAE et le coefficient de détermination R^2, permettant une comparaison objective et rigoureuse.

L'ensemble de ces éléments méthodologiques établit un cadre expérimental structuré, garantissant la validité scientifique des analyses comparatives et la reproductibilité des résultats. En combinant un dispositif de mesure réel, des jeux de données représentatifs et des architectures d'apprentissage profond optimisées, ce chapitre pose ainsi les bases nécessaires à l'étude approfondie des performances des modèles de localisation.

Le chapitre suivant sera consacré à la présentation et à l'analyse détaillée des résultats expérimentaux. Il proposera une comparaison quantitative et qualitative des architectures étudiées, afin d'identifier leurs forces, leurs limites et leur aptitude à prédire avec précision les positions spatiales dans des environnements souterrains complexes où les systèmes de positionnement conventionnels sont indisponibles

4. RESULTATS

Ce chapitre présente l'analyse détaillée des résultats obtenus lors de l'évaluation des trois architectures de réseaux de neurones étudiées, à savoir le FCNN, le MLP et le LSTM, appliquées à la tâche de localisation souterraine à partir de données radios issus des mesures RSSI et CSI. L'objectif principal de cette analyse est de comparer les performances de ces modèles afin d'identifier l'architecture la plus adaptée à la modélisation du canal radio et à l'estimation précise des coordonnées spatiales dans un environnement minier réel.

L'évaluation repose sur plusieurs critères complémentaires permettant d'obtenir une analyse globale et rigoureuse des performances. Elle inclut d'une part l'étude quantitative de la précision des prédictions à l'aide de métriques statistiques telles que l'erreur quadratique moyenne (RMSE), l'erreur absolue moyenne (MAE) et le coefficient de détermination (R^2), et d'autre part une analyse qualitative basée sur la comparaison visuelle entre les positions réelles et les positions estimées. Cette double approche permet de caractériser à la fois la précision numérique des modèles et leur comportement spatial global.

Les résultats présentés dans ce chapitre visent également à examiner la robustesse des architectures face aux conditions complexes de propagation radio propres aux environnements souterrains, notamment les effets de multi-trajets, les variations d'atténuation et les situations de non-visibilité directe. Une attention particulière est accordée à la comparaison des performances entre les différents jeux de données et configurations expérimentales, afin d'évaluer la capacité de généralisation des modèles et leur pertinence pour des applications réelles de localisation sans infrastructure GPS.

L'ensemble des analyses proposées permettra ainsi de mettre en évidence les forces et les limites de chaque architecture, tout en fournissant une interprétation approfondie des résultats obtenus, préalable nécessaire à la discussion finale et aux perspectives d'amélioration présentées dans le chapitre suivant.

4.1 Évaluation selon les métriques RMSE, MAE et R²

Les résultats présentés dans le Tableau 2 mettent en évidence des différences significatives entre les trois architectures étudiées pour la prédiction des coordonnées spatiales. Le modèle FCNN se distingue clairement comme l'architecture la plus performante, en présentant simultanément les erreurs les plus faibles et les coefficients de détermination les plus élevés sur les deux axes. Il atteint un RMSE de 0,1739 m sur l'axe X et de 1,8552 m sur l'axe Y, ainsi que des MAE de 0,0813 m et 1,1390 m respectivement. Les scores R^2 (0,9497 pour X et 0,9825 pour Y) indiquent une forte concordance entre les positions estimées et réelles.

La supériorité du FCNN peut s'expliquer par sa capacité à apprendre des interactions non linéaires complexes entre les différentes composantes du signal radio. En environnement minier souterrain, la propagation radio est fortement dominée par les effets de multi-trajets, d'évanouissement sélectif en fréquence et de réflexions multiples sur les parois rocheuses et structures métalliques. Ces phénomènes génèrent des signatures CSI dont les sous-porteuses présentent des variations corrélées et structurées. Le FCNN, grâce à sa profondeur et à ses couches successives de transformation, est capable d'extraire progressivement ces structures internes et de modéliser les relations complexes entre variations fréquentielles du canal et position spatiale. En d'autres termes, il exploite plus efficacement la richesse informationnelle contenue dans le CSI.

Le modèle MLP présente des performances intermédiaires, avec un RMSE de 0,2109 m pour X et de 2,1104 m pour Y, ainsi qu'un MAE de 0,1004 m et 1,2841 m respectivement. Bien qu'il repose également sur une modélisation non linéaire, sa structure plus simple limite sa capacité à représenter les interactions complexes entre les différentes sous-porteuses. Physiquement, cela signifie qu'il capte moins efficacement les motifs de propagation résultant des combinaisons d'interférences constructives et destructives du canal.

Le modèle LSTM obtient les performances les plus faibles, avec un RMSE de 0,2417 m sur X et 2,4833 m sur Y. Cette performance plus faible peut s'expliquer par une inadéquation entre la structure du modèle et la nature physique des données. Le LSTM est conçu pour exploiter des dépendances temporelles ou séquentielles, alors que dans cette étude, les échantillons CSI représentent principalement des états spatiaux instantanés du canal. Même si une corrélation locale existe entre positions voisines, la structure dominante de l'information reste fréquentielle et non temporelle. Ainsi, les mécanismes de mémoire interne du LSTM ne sont pas pleinement exploités.

Ces résultats montrent que la performance d'un modèle de localisation ne dépend pas uniquement de sa complexité algorithmique, mais de son adéquation avec la structure physique du canal radio. Dans ce contexte, le FCNN apparaît comme le meilleur compromis entre capacité de représentation et adaptation à la structure fréquentielle du CSI, ce qui explique sa supériorité pour la localisation en environnement souterrain.

Tableau 2
Comparaison des performances (RMSE & MAE, en mètres) des modèles FCNN, MLP et LSTM pour la prédiction des coordonnées X/Y.

Model	RMSE (X)	RMSE (Y)	MAE (X)	MAE (Y)	R^2 Score (X)	R^2 Score (Y)
FCNN	0.1739	1.8552	0.0813	1.1390	0.9497	0.9825
MLP	0.2109	2.1104	0.1004	1.2841	0.9260	0.9767
LSTM	0.2417	2.4833	0.1014	1.4440	0.9028	0.9687

Une observation importante concerne la différence de performance entre les axes X et Y, où les erreurs de localisation sur l'axe Y sont systématiquement plus élevées que sur l'axe X. Cette différence s'explique en grande partie par la géométrie même du tunnel ainsi que par les mécanismes physiques de propagation électromagnétique dans un environnement confiné.

L'axe X correspond à la largeur du tunnel, dont l'étendue spatiale est relativement limitée. Dans cette direction, de faibles variations de position entraînent des

changements significatifs dans les conditions de réflexion sur les parois latérales, produisant des signatures CSI plus distinctives et plus facilement discriminables par le modèle.

À l'inverse, l'axe Y représente la direction longitudinale du tunnel, dont l'étendue spatiale est beaucoup plus importante. Dans cette direction, la propagation suit davantage un comportement de guide d'onde, où l'énergie électromagnétique se propage sur de longues distances à travers des réflexions successives sur les parois, le plafond et le sol. Ce phénomène tend à conserver certaines structures globales du signal sur plusieurs mètres, réduisant ainsi la sensibilité des signatures CSI aux petites variations de position le long du tunnel.

Par conséquent, deux positions proches sur l'axe Y peuvent produire des signatures radio relativement similaires, augmentant l'ambiguïté spatiale et rendant l'estimation plus difficile. Cette propriété physique explique naturellement pourquoi les erreurs de localisation sur l'axe longitudinal sont plus élevées que sur l'axe transversal.

4.2 Analyse de la CDF des erreurs de localisation

4.2.1 Modèle MLP

La Figure 22 présente la fonction de répartition cumulative (CDF) des erreurs de localisation obtenues avec le modèle MLP en utilisant l'ensemble des caractéristiques d'entrée, à savoir l'amplitude, la phase et le RSSI. Le graphique supérieur correspond à la distribution cumulative des erreurs sur l'axe X, tandis que le graphique inférieur illustre la distribution des erreurs sur l'axe Y. Cette représentation probabiliste permet d'évaluer non seulement la précision moyenne du modèle, mais également la proportion de prédictions respectant un seuil d'erreur donné, ce qui constitue un indicateur particulièrement pertinent pour l'analyse des performances en localisation.

Pour l'axe X, la courbe CDF présente une croissance rapide et atteint une probabilité proche de l'unité pour des erreurs relativement faibles. Les résultats indiquent qu'environ 90 % des estimations présentent une erreur inférieure à 1 mètre, ce qui traduit une dispersion limitée des erreurs et une forte stabilité prédictive sur cette dimension. Cette performance peut s'expliquer par l'étendue spatiale relativement

réduite de l'axe X, comprise approximativement entre 0 et 2,5 mètres, ce qui réduit la variabilité du canal radio et facilite l'apprentissage des relations entre caractéristiques du signal et position spatiale. Le modèle MLP démontre ainsi une capacité satisfaisante à approximer la fonction de localisation dans les régions où les variations du signal sont modérées et spatialement contraintes.

En revanche, l'analyse de la CDF sur l'axe Y révèle une distribution d'erreurs plus étendue et une progression plus graduelle de la courbe. Bien qu'environ 80 % des prédictions se situent en dessous d'un seuil d'erreur de 5 mètres, certaines estimations présentent des écarts pouvant atteindre des valeurs nettement plus élevées, proches de 30 mètres. Cette dispersion accrue reflète la complexité plus importante de l'estimation sur cette dimension, liée principalement à la plus grande portée spatiale de l'axe Y, qui s'étend jusqu'à plusieurs dizaines de mètres le long du corridor minier. L'augmentation de la distance de propagation entraîne une accumulation d'effets physiques tels que l'atténuation du signal, les réflexions multiples, les phénomènes de multi-trajets et les interférences, ce qui rend la relation entre les caractéristiques radio et la position plus difficile à modéliser pour une architecture entièrement connectée.

Dans l'ensemble, l'analyse de la CDF confirme que le modèle MLP offre des performances fiables pour la prédiction de la coordonnée X, mais présente des limitations pour l'estimation de la coordonnée Y, dont la distribution d'erreurs est plus large. Cette observation est cohérente avec les résultats quantitatifs précédemment obtenus à l'aide des métriques RMSE et MAE, et souligne l'influence déterminante de l'échelle spatiale et de la complexité du canal sur la précision de localisation. Elle met également en évidence les limites des architectures entièrement connectées lorsqu'il s'agit de modéliser des environnements présentant des relations non linéaires fortement variables, comme c'est le cas dans les tunnels souterrains.

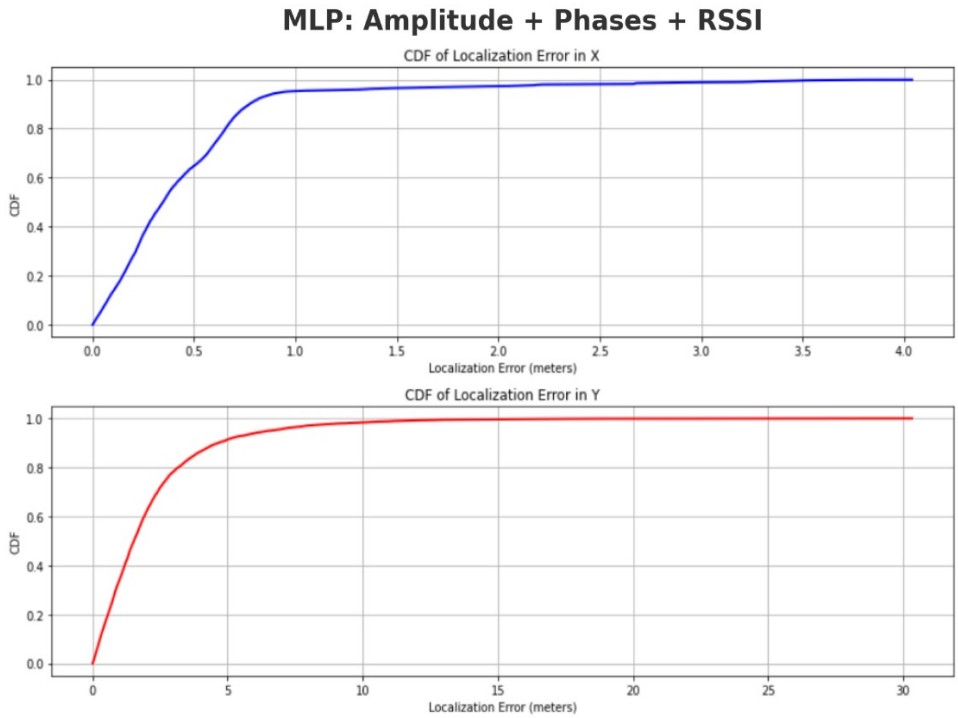

Figure 22
Localisation CDF des erreurs de localisation pour le modèle MLP

4.2.2 Modèle LSTM

La Figure 23 présente la fonction de répartition cumulative (CDF) des erreurs de localisation obtenues avec le modèle LSTM, entraîné à partir des caractéristiques combinées d'amplitude, de phase et de RSSI. Le graphique supérieur illustre la distribution cumulative des erreurs de prédiction pour la coordonnée X, tandis que le graphique inférieur représente la distribution des erreurs associées à la coordonnée Y. L'utilisation de la CDF permet d'évaluer non seulement l'erreur moyenne, mais également la proportion de prédictions respectant un seuil de précision donné, offrant ainsi une vision probabiliste complète des performances du modèle.

Pour l'axe X, le modèle LSTM présente une précision globalement élevée. La courbe croît très rapidement et atteint une probabilité proche de l'unité pour des valeurs d'erreur faibles, indiquant qu'environ 95 % des prédictions présentent une erreur inférieure à 0,5 mètre. Cette croissance abrupte traduit une faible dispersion des

erreurs et une stabilité notable du modèle sur cette dimension. Ce comportement s'explique en grande partie par l'étendue spatiale limitée de l'axe X (environ 0 à 2,5 mètres), qui réduit la variabilité du canal radio et simplifie la relation entre les caractéristiques du signal et la position spatiale. Dans ce contexte, même une architecture séquentielle telle que le LSTM est capable d'apprendre efficacement la fonction de régression associée à cette dimension.

En revanche, l'analyse de la CDF sur l'axe Y met en évidence des performances plus hétérogènes. Bien que la majorité des prédictions se situent en dessous d'un seuil d'erreur de 5 mètres, la courbe progresse plus lentement et révèle une dispersion nettement plus importante, avec certaines erreurs extrêmes pouvant dépasser 30 mètres. Cette distribution plus étendue reflète la complexité accrue de la prédiction le long de cette dimension, dont la portée spatiale est significativement plus grande (jusqu'à environ 50 mètres). L'augmentation de la distance de propagation entraîne une accumulation d'effets physiques tels que l'atténuation du signal, les réflexions multiples, les phénomènes de multi-trajets et les perturbations dues au bruit environnemental, ce qui complique la modélisation de la relation entre signatures radio et position.

Ces résultats montrent que, malgré sa capacité théorique à modéliser des dépendances séquentielles, le modèle LSTM ne parvient pas à exploiter pleinement son potentiel dans ce contexte. En effet, la tâche de localisation considérée repose principalement sur des relations spatiales instantanées plutôt que sur des dépendances temporelles marquées, ce qui limite l'avantage structurel des architectures récurrentes. Cette observation suggère que les mécanismes de mémoire interne du LSTM ne sont pas suffisamment sollicités pour améliorer significativement la précision globale.

Dans l'ensemble, l'analyse de la CDF confirme que le modèle LSTM est capable de fournir des estimations fiables pour la coordonnée X, mais qu'il présente des limitations plus prononcées pour la coordonnée Y, caractérisée par une variabilité plus importante. Ces résultats sont cohérents avec les métriques quantitatives

précédemment présentées et indiquent que les architectures séquentielles ne constituent pas nécessairement le choix optimal pour des tâches de localisation statique en environnement souterrain. Ils soulignent également l'importance d'adapter le choix de l'architecture d'apprentissage à la nature structurelle des données et aux propriétés physiques du canal radio.

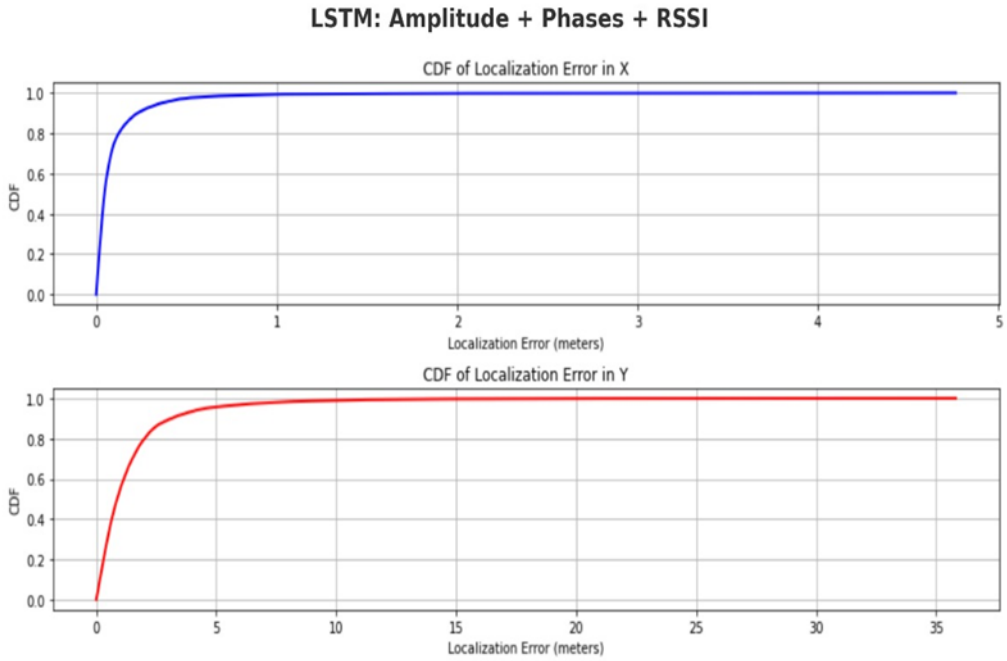

Figure 23
Localisation CDF des erreurs de localisation pour le modèle LSTM

4.2.3 Modèle FCNN

La Figure 24 présente la fonction de répartition cumulative (CDF) des erreurs de localisation obtenues avec le modèle FCNN, entraîné à partir de l'ensemble des caractéristiques radios disponibles, à savoir l'amplitude, la phase et le RSSI. Le graphique supérieur illustre la distribution cumulative des erreurs associées à la coordonnée X, tandis que le graphique inférieur représente celles correspondant à la coordonnée Y.

Pour l'axe X, le modèle FCNN démontre une précision remarquable. La courbe CDF croît très rapidement et atteint une probabilité proche de l'unité pour des valeurs d'erreur très faibles, indiquant qu'environ 95 % des prédictions présentent une erreur inférieure à 0,5 mètre. Cette montée abrupte traduit une dispersion extrêmement limitée des erreurs, révélant une grande stabilité du modèle sur cette dimension. Ce comportement s'explique en partie par l'étendue spatiale relativement restreinte de l'axe X (environ 0 à 2,5 mètres), qui réduit la variabilité du canal radio et simplifie la relation fonctionnelle entre les signatures du signal et la position. Toutefois, la qualité de ces résultats témoigne également de la capacité du FCNN à extraire efficacement les motifs discriminants présents dans les caractéristiques CSI, grâce à ses mécanismes d'extraction hiérarchique de caractéristiques.

L'analyse de la CDF sur l'axe Y confirme également les performances élevées du modèle. Environ 90 % des estimations présentent une erreur inférieure à 5 mètres, et la courbe atteint progressivement la saturation sans présenter de traîne significative, ce qui indique une faible proportion de valeurs aberrantes. Cette distribution relativement compacte est particulièrement notable compte tenu de l'étendue spatiale beaucoup plus importante de cette dimension, qui peut atteindre plusieurs dizaines de mètres le long du corridor minier. L'augmentation de la distance de propagation entraîne généralement une complexité accrue du canal radio, caractérisée par des phénomènes d'atténuation, de multi-trajets, de réflexions sur les parois et d'interférences. Malgré ces conditions défavorables, le FCNN parvient à maintenir une dispersion d'erreur limitée, ce qui témoigne d'une robustesse élevée face aux perturbations environnementales.

Comparativement aux modèles MLP et LSTM, le FCNN présente la distribution d'erreurs la plus compacte et la plus stable sur les deux axes, ce qui indique une meilleure capacité de généralisation et une plus grande fiabilité prédictive. Cette supériorité s'explique principalement par la nature convolutionnelle de l'architecture, qui permet d'exploiter explicitement la structure interne des vecteurs CSI et de détecter des motifs locaux pertinents pour la localisation. Contrairement aux architectures entièrement connectées ou récurrentes, le FCNN peut apprendre des

représentations hiérarchiques des caractéristiques du signal, ce qui lui confère un avantage significatif dans les environnements présentant des relations non linéaires complexes.

Dans l'ensemble, l'analyse de la CDF confirme que le modèle FCNN constitue l'architecture la plus performante parmi celles étudiées pour la tâche de localisation souterraine. Il offre simultanément une haute précision, une faible dispersion des erreurs et une forte robustesse face aux conditions de propagation difficiles caractéristiques des tunnels miniers. Ces résultats soulignent l'importance d'utiliser des architectures capables d'exploiter la structure spatiale des données radio pour obtenir des estimations de position fiables dans des environnements contraints où les systèmes de localisation traditionnels ne sont pas disponibles.

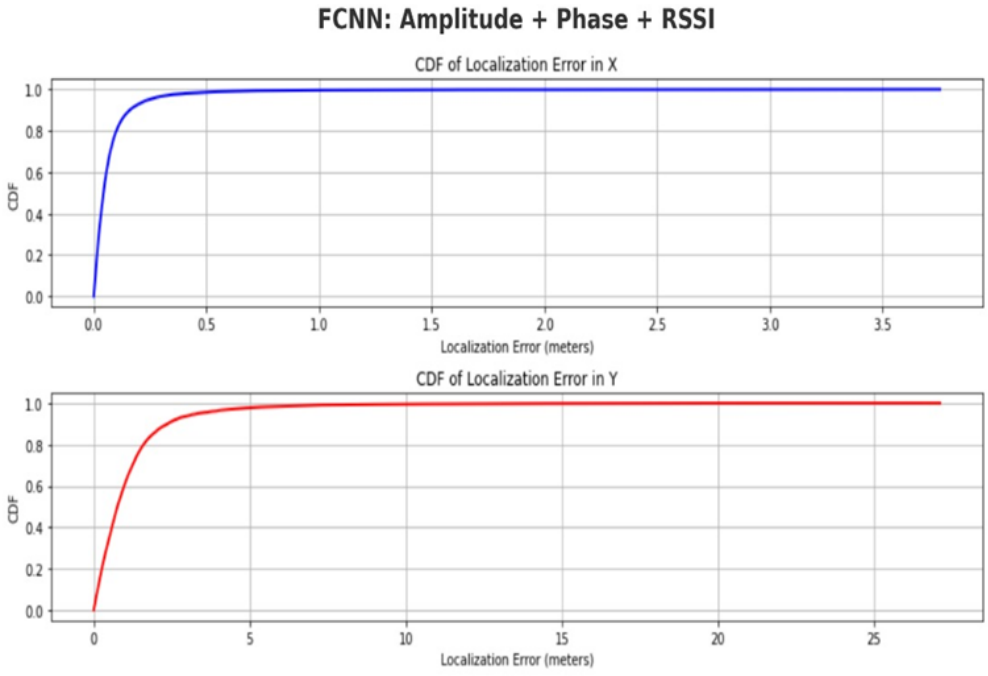

Figure 24
Localisation CDF des erreurs de localisation pour le modèle FCNN

4.3 Synthèse comparative des performances basée sur les CDF

L'analyse comparative des fonctions de répartition cumulative des erreurs de localisation met clairement en évidence l'influence déterminante de l'architecture des modèles sur la précision et la robustesse des estimations spatiales. L'étude conjointe des distributions d'erreurs pour les axes X et Y montre que les performances ne doivent pas être évaluées uniquement à partir de métriques globales, mais également à travers l'analyse de la dispersion et de la stabilité des erreurs, ce que permet précisément l'utilisation des courbes CDF.

Dans l'ensemble, le modèle FCNN se distingue comme l'architecture la plus performante, présentant les distributions d'erreurs les plus concentrées et les plus régulières sur les deux axes. Sa courbe CDF croît systématiquement plus rapidement et atteint la saturation pour des valeurs d'erreur plus faibles, indiquant qu'une proportion plus importante de prédictions respecte des seuils de précision stricts. Ce comportement traduit une meilleure capacité de généralisation et une plus grande robustesse face aux variations du canal radio, notamment dans les conditions difficiles de propagation caractéristiques des environnements souterrains.

Le modèle MLP présente des performances intermédiaires, avec une distribution d'erreurs relativement compacte sur l'axe X mais plus dispersée sur l'axe Y. Cette différence souligne la limite des architectures entièrement connectées lorsqu'il s'agit de modéliser des relations fortement non linéaires et spatialement variables, telles que celles induites par les phénomènes de propagation multi-trajets dans les tunnels. Quant au modèle LSTM, bien qu'il montre une bonne précision pour la dimension X, ses performances restent globalement inférieures pour la coordonnée Y, ce qui suggère que les dépendances temporelles exploitées par ce type d'architecture ne constituent pas un facteur déterminant dans cette tâche de localisation statique.

Ces observations confirment que la nature structurelle des données joue un rôle central dans le choix de l'architecture d'apprentissage. Les résultats démontrent que les modèles capables d'extraire efficacement des caractéristiques spatiales locales,

comme le FCNN, sont particulièrement adaptés à la modélisation du canal radio en environnement souterrain.

En conclusion, l'analyse des CDF valide la supériorité du modèle FCNN pour la tâche étudiée et souligne l'importance d'adapter l'architecture du réseau à la structure physique des données radio. Cette étape comparative constitue ainsi un élément clé pour identifier les solutions les plus appropriées au développement de systèmes de localisation robustes et précis destinés aux environnements miniers souterrains.

4.4 Évaluation du meilleur modèle sur les nouveaux jeux de données

À l'issue de l'analyse comparative détaillée des architectures présentées dans les sections précédentes, le modèle FCNN a été identifié comme l'approche la plus performante pour la tâche de localisation souterraine. Cette conclusion repose sur l'ensemble des indicateurs quantitatifs et probabilistes analysés, notamment les valeurs de RMSE et de MAE, les coefficients de détermination R^2 ainsi que la distribution cumulative des erreurs. Ces résultats ont montré que le FCNN offre simultanément une précision élevée, une faible dispersion des erreurs et une robustesse supérieure face aux variations du canal radio, ce qui en fait le candidat le plus approprié pour une validation approfondie.

Dans une perspective de validation expérimentale réaliste, il est toutefois essentiel d'évaluer la capacité de généralisation du modèle, c'est-à-dire son aptitude à maintenir des performances satisfaisantes lorsqu'il est appliqué à des données non utilisées lors de l'entraînement. Cette étape constitue un critère fondamental pour toute application réelle de localisation, car un modèle performant uniquement sur les données d'apprentissage pourrait présenter un surapprentissage et ne pas être utilisable dans des environnements opérationnels.

Afin d'évaluer cette capacité de généralisation, le modèle FCNN sélectionné a été testé sur un nouveau jeu de données collecté dans un autre corridor de la même mine souterraine. Comme décrit à la Section 3.3, ce second ensemble de données présente des caractéristiques environnementales plus complexes, incluant une géométrie de tunnel plus irrégulière, une distribution spatiale différente des points de mesure et une

proportion plus élevée de situations de non-visibilité directe (NLOS). Ces conditions introduisent une variabilité accrue du canal radio et constituent ainsi un scénario d'évaluation plus exigeant que celui du jeu de données initial.

L'évaluation du modèle sur ces nouvelles données a été réalisée en utilisant exactement les mêmes métriques de performance que celles employées précédemment, à savoir le RMSE, le MAE, le coefficient de détermination R^2 ainsi que la fonction de répartition cumulative (CDF) des erreurs de localisation. Cette cohérence méthodologique garantit une comparaison équitable et rigoureuse entre les différents environnements expérimentaux et permet d'analyser de manière fiable la robustesse du modèle face à des conditions de propagation non observées lors de l'apprentissage.

Cette étape constitue ainsi une validation externe essentielle, visant à vérifier si le modèle conserve ses capacités prédictives dans des contextes plus réalistes et plus complexes. Elle permet non seulement d'évaluer la stabilité des performances, mais également d'estimer le potentiel réel du modèle pour une utilisation pratique dans des systèmes de localisation souterraine.

4.4.1 Évaluation quantitative des performances

Les performances quantitatives obtenues par le modèle FCNN sur le nouveau jeu de données sont résumées dans le Tableau 3. Ce tableau présente les principales métriques d'évaluation utilisées dans cette étude, à savoir le RMSE, le MAE et le coefficient de détermination R^2, calculées séparément pour les coordonnées spatiales X et Y. Ces indicateurs permettent d'évaluer simultanément la précision globale, l'erreur moyenne réelle et la capacité explicative du modèle[31].

Tableau 3
Performances du modèle FCNN sur les nouveaux jeux de données.

Métrique	Coordonnée X	Coordonnée Y
RMSE (m)	1,84	1,99
MAE (m)	0,85	1,33
R^2	0,96	0,99

L'analyse de ces résultats montre que le modèle FCNN maintient un niveau de performance élevé malgré l'augmentation significative de la complexité de l'environnement expérimental. Les coefficients de détermination obtenus, supérieurs à 0,95 pour les deux axes, indiquent que le modèle est capable d'expliquer la quasi-totalité de la variance des données observées. Cette forte valeur de R^2 témoigne d'une excellente concordance entre les coordonnées prédites et les positions réelles, confirmant ainsi la robustesse du modèle face à des conditions de propagation différentes de celles rencontrées lors de l'entraînement.

Les valeurs de RMSE et de MAE demeurent également relativement faibles comptes tenus de la géométrie plus complexe du corridor étudié. L'augmentation du RMSE observée par rapport aux résultats obtenus sur le jeu de données initial constitue un comportement attendu et cohérent du point de vue physique. En effet, le nouveau scénario expérimental présente une proportion plus élevée de conditions de non-visibilité directe (NLOS), une géométrie de tunnel plus irrégulière ainsi qu'une plus grande variabilité spatiale du signal radio. Ces facteurs introduisent une complexité accrue dans la relation entre les caractéristiques du canal et la position, ce qui rend la tâche de prédiction intrinsèquement plus difficile.

Il convient également de noter que l'écart légèrement plus élevé observé sur l'axe Y est cohérent avec les analyses précédentes, cette dimension étant associée à une portée spatiale plus importante et à une accumulation plus prononcée des effets de

propagation tels que l'atténuation, les réflexions multiples et les interférences. Malgré ces contraintes, le modèle conserve une précision satisfaisante, ce qui démontre sa capacité de généralisation et confirme qu'il ne s'agit pas d'un modèle surajusté aux données d'entraînement.

Dans l'ensemble, ces résultats quantitatifs constituent une validation expérimentale solide de la robustesse du FCNN. Ils démontrent que l'architecture sélectionnée est capable de maintenir des performances élevées même lorsqu'elle est appliquée à des données issues d'un environnement plus complexe et non observé auparavant. Cette propriété est essentielle pour toute application réelle de localisation, car elle garantit que le modèle peut être déployé dans des scénarios opérationnels présentant des conditions variables sans perte significative de précision.

4.4.2 Analyse de l'erreur de localisation et de la fonction de répartition cumulative

La Figure 25 présente la fonction de répartition cumulative (CDF) des erreurs de localisation obtenues avec le modèle FCNN appliqué au nouveau jeu de données correspondant à la section B du tunnel minier. Le graphique supérieur illustre la distribution cumulative des erreurs absolues associées à la coordonnée X, tandis que le graphique inférieur représente celles de la coordonnée Y. Cette représentation probabiliste permet d'évaluer de manière détaillée la fiabilité du modèle en quantifiant la proportion de prédictions dont l'erreur reste inférieure à un seuil donné, fournissant ainsi une mesure plus complète de la performance que les métriques globales seules. L'analyse de la courbe relative à l'axe X montre une croissance très rapide de la CDF pour de faibles valeurs d'erreur, indiquant qu'une grande majorité des estimations se situe dans une plage d'erreur réduite. Cette montée abrupte traduit une dispersion limitée des erreurs et confirme que le modèle parvient à capturer efficacement les relations entre les signatures radio et la position spatiale le long de cette dimension. Ce comportement est cohérent avec la portée spatiale plus restreinte de l'axe X, qui limite la variabilité du canal et réduit la complexité de la fonction de régression à apprendre. La saturation rapide de la courbe suggère en outre que les erreurs importantes sont rares, ce qui constitue un indicateur de stabilité et de robustesse du modèle.

L’analyse de la CDF sur l’axe Y met également en évidence une distribution globalement favorable, bien que légèrement plus étalée que celle observée pour l’axe X. La progression plus graduelle de la courbe reflète une dispersion d’erreur plus importante, ce qui est attendu compte tenu de l’étendue spatiale plus grande de cette dimension ainsi que de l’influence plus prononcée des phénomènes de propagation radio dans cette direction. En effet, la longueur accrue du corridor minier introduit une accumulation d’effets physiques tels que l’atténuation progressive du signal, les réflexions multiples sur les parois rocheuses, les phénomènes de multi-trajets et les perturbations dues aux obstacles métalliques. Malgré ces contraintes, la courbe atteint rapidement des niveaux élevés de probabilité cumulative, ce qui indique que la majorité des prédictions reste contenue dans des seuils d’erreur raisonnables. Ce comportement témoigne de la capacité du modèle à maintenir une précision satisfaisante même lorsque les conditions de propagation deviennent plus complexes et plus variables.

La comparaison qualitative entre les distributions d’erreurs des deux axes met en évidence une asymétrie caractéristique des systèmes de localisation radio en environnements contraints : la dimension associée à la plus grande portée spatiale présente généralement une dispersion d’erreurs plus importante. Cette observation est conforme aux principes physiques de la propagation électromagnétique, selon lesquels l’augmentation de la distance et de la complexité géométrique du milieu entraîne une dégradation progressive de l’information contenue dans le signal. Le fait que le modèle conserve néanmoins une distribution d’erreurs relativement compacte sur cette dimension confirme sa robustesse et sa capacité de généralisation.

Dans l’ensemble, l’analyse des courbes CDF pour la section B démontre que le modèle FCNN maintient des performances de localisation fiables même lorsqu’il est appliqué à un environnement présentant une géométrie plus complexe et une proportion accrue de conditions NLOS. La forte concentration des erreurs dans des plages de faible amplitude, combinée à la faible occurrence de valeurs extrêmes, indique que le modèle fournit des estimations stables et cohérentes dans la majorité des cas. Ces résultats constituent une validation expérimentale solide de la capacité

du FCNN à s'adapter à des scénarios non observés lors de l'entraînement et confirment son aptitude à être utilisé dans des applications réelles de localisation souterraine, où la robustesse face aux variations environnementales constitue une exigence fondamentale.

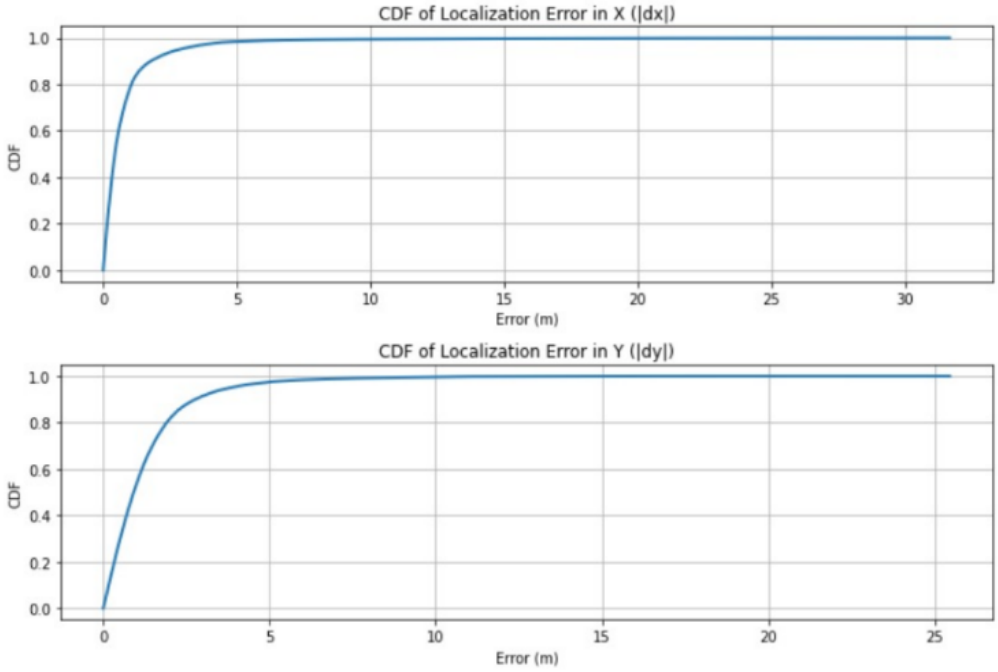

Figure 25
CDF de l'erreur de distance de localisation pour le modèle FCNN sur le nouveau jeu de données.

4.4.3 Analyse de la convergence des pertes d'entraînement et de validation

La Figure 26 illustre l'évolution des fonctions de perte d'entraînement et de validation du modèle FCNN en fonction du nombre d'époques. Ces courbes constituent un indicateur essentiel pour analyser le comportement d'apprentissage du réseau, car elles permettent d'évaluer simultanément la vitesse de convergence, la stabilité de l'optimisation et la capacité de généralisation du modèle.

On observe dans un premier temps une diminution rapide de la perte durant les premières itérations, ce qui traduit une phase d'apprentissage initial efficace au cours de laquelle le modèle capture les relations dominantes entre les caractéristiques du

signal radio et les coordonnées spatiales. Cette décroissance rapide indique que l'optimiseur converge correctement vers une région de minimum de la fonction de coût et que les paramètres du réseau s'ajustent efficacement dès les premières époques.

Par la suite, la décroissance des courbes devient plus progressive, reflétant une phase de raffinement de l'apprentissage dans laquelle le modèle ajuste plus finement ses poids afin de réduire les erreurs résiduelles. La stabilisation des deux courbes autour de valeurs faibles témoigne d'un processus d'entraînement convergent et stable, caractérisé par l'absence d'oscillations importantes ou de divergence du gradient.

La proximité entre les courbes de perte d'entraînement et de validation constitue un indicateur particulièrement significatif. Elle suggère que le modèle ne se contente pas de mémoriser les données d'apprentissage, mais qu'il parvient à extraire des représentations généralisables des caractéristiques d'entrée. En effet, l'absence d'écart croissant entre les deux courbes indique que le phénomène de surapprentissage est négligeable, ce qui confirme la pertinence des choix architecturaux et des stratégies de régularisation adoptées, notamment l'utilisation de mécanismes tels que le dropout et la normalisation par lots.

On note également la présence de fluctuations ponctuelles sur la courbe de validation à certaines époques. Ces variations localisées sont typiques des processus d'apprentissage sur des données réelles et peuvent être attribuées à la variabilité intrinsèque des échantillons de validation ou à la présence d'observations plus difficiles à prédire. Toutefois, leur amplitude limitée et leur caractère non systématique confirment que ces fluctuations n'affectent pas la stabilité globale de l'apprentissage.

Dans l'ensemble, l'analyse de la dynamique des pertes démontre que le modèle FCNN converge de manière fiable vers une solution stable tout en conservant une capacité de généralisation satisfaisante. Ce comportement constitue un indicateur fort de la robustesse de l'architecture et confirme que le modèle est correctement entraîné, sans signe de sous-apprentissage ni de surapprentissage. Ces observations renforcent la validité des résultats obtenus lors des évaluations quantitatives et probabilistes précédemment présentées.

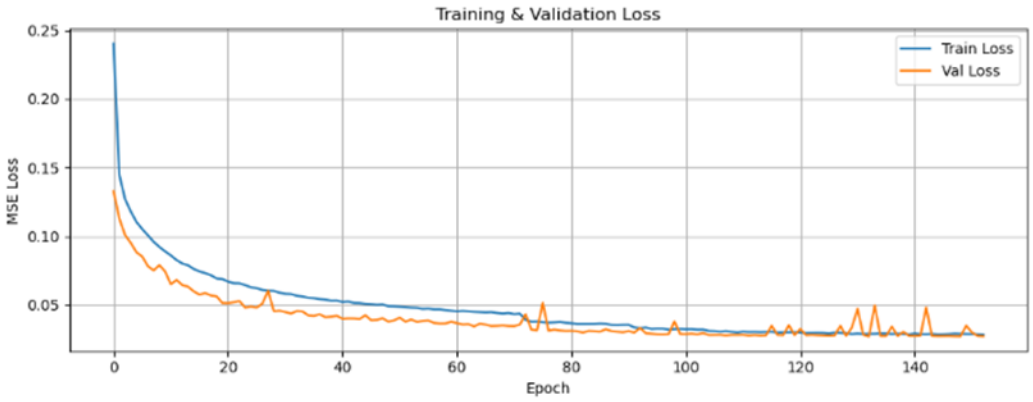

Figure 26
Évolution des pertes d'entraînement et de validation du modèle FCNN.

4.5 Discussion

L'évaluation du modèle FCNN sur les nouveaux jeux de données constitue une étape déterminante pour apprécier la robustesse et la validité scientifique de l'approche proposée. Les résultats obtenus montrent que le modèle conserve des performances élevées malgré l'augmentation significative de la complexité de l'environnement expérimental. En effet, le second jeu de données se caractérise par une géométrie de tunnel plus irrégulière, une proportion accrue de conditions de non-visibilité directe (NLOS), ainsi qu'une variabilité plus importante des caractéristiques du canal radio. Dans ce contexte plus exigeant, le maintien d'une précision de localisation satisfaisante indique que le modèle ne se limite pas à reproduire les patterns du jeu de données initial, mais qu'il a effectivement appris une représentation généralisable de la relation entre signatures radio et position spatiale.

Cette capacité de généralisation constitue un critère essentiel pour les systèmes de localisation basés sur l'apprentissage automatique, car elle conditionne leur applicabilité dans des environnements réels où les conditions de propagation sont rarement identiques à celles observées lors de l'entraînement. Les performances obtenues démontrent que l'architecture FCNN possède une aptitude notable à extraire des caractéristiques discriminantes robustes, capables de rester informatives même lorsque les propriétés statistiques du canal évoluent. Cette propriété suggère que les

filtres convolutionnels apprennent des motifs physiques intrinsèques liés à la propagation électromagnétique, plutôt que de simples corrélations spécifiques au jeu de données d'apprentissage.

L'analyse comparative réalisée avec les modèles MLP et LSTM confirme également l'importance du choix architectural dans la conception de systèmes de localisation radio. Alors que les architectures entièrement connectées traitent les caractéristiques d'entrée comme des variables indépendantes et que les architectures récurrentes privilégient les dépendances temporelles, le FCNN exploite explicitement la structure interne des vecteurs CSI. Cette capacité à capturer des relations locales et hiérarchiques entre sous-porteuses constitue un avantage déterminant dans les environnements souterrains, où les phénomènes de multi-trajets, de diffusion et de réflexion produisent des signatures spectrales complexes et fortement corrélées.

Par ailleurs, l'analyse des distributions d'erreurs et des courbes CDF montre que le modèle présente non seulement une précision moyenne élevée, mais également une dispersion d'erreurs relativement limitée. Ce résultat est particulièrement important dans les applications pratiques, où la fiabilité d'un système de localisation dépend davantage de la stabilité des estimations que de la seule minimisation de l'erreur moyenne. La faible proportion d'erreurs extrêmes observée confirme que le modèle demeure robuste face aux perturbations locales du signal, telles que les occultations, les interférences ou les variations géométriques du tunnel.

Les performances obtenues peuvent également être comparées à celles rapportées dans la littérature scientifique (voir Tableau 4). Les systèmes de localisation Wi-Fi traditionnels basés sur le RSSI, tels que RADAR et Horus, rapportent respectivement des erreurs de localisation de 2,28 m et 1,95 m dans des environnements intérieurs contrôlés. L'exploitation des informations CSI permet généralement d'améliorer la précision, comme l'illustrent les approches FILA et ConFi, qui atteignent des erreurs de 1,79 m et 1,37 m. Dans le contexte minier, Qiao et al. (2025) ont proposé une approche combinant des mesures RSSI, un filtre de Kalman et une stratégie de

localisation coopérative, obtenant une erreur moyenne de 1,55 m dans une mine de charbon couvrant une surface d'environ 500 m².

En comparaison, le modèle FCNN développé dans cette étude atteint, sur l'ancienne section de la mine, un RMSE de 0,1739 m selon l'axe X et de 1,855 m selon l'axe Y, avec des coefficients de détermination R^2 de 0,9497 et 0,9828 respectivement. Sur la nouvelle section, caractérisée par une surface beaucoup plus importante de 2275 m² ainsi qu'une géométrie plus complexe, le modèle obtient un RMSE de 1,7660 m sur l'axe X et de 1,8362 m sur l'axe Y, accompagné de coefficients R^2 de 0,9609 et 0,9895. Malgré l'augmentation significative de la taille de la zone étudiée, les performances demeurent élevées et témoignent de la capacité du modèle à maintenir une bonne précision dans des conditions de propagation plus difficiles.

Il est également important de souligner que la comparaison directe avec les travaux de la littérature doit être interprétée avec prudence. Les différentes études reposent sur des configurations expérimentales, des dimensions de zones, des densités de points de mesure et des métriques d'évaluation parfois différentes. De plus, la majorité des travaux existants ont été réalisés dans des environnements intérieurs relativement contrôlés, alors que les résultats présentés dans ce mémoire ont été obtenus dans une mine souterraine réelle caractérisée par de nombreux phénomènes de multi-trajets, des zones NLOS, des irrégularités géométriques importantes et des variations spatiales marquées du canal radio. Dans ce contexte particulièrement contraignant, les performances obtenues démontrent que la combinaison des caractéristiques RSSI et CSI associée à une architecture FCNN constitue une approche robuste et compétitive pour la localisation en environnement minier souterrain.

Il convient toutefois de souligner que certaines limitations subsistent. Les erreurs les plus importantes apparaissent principalement dans les zones où les conditions de propagation sont les plus sévères, notamment dans les régions caractérisées par une forte atténuation ou des trajets multiples dominants. Ces cas extrêmes mettent en évidence les limites inhérentes aux approches fondées uniquement sur les

caractéristiques radio et suggèrent que l'intégration d'informations complémentaires, telles que des contraintes géométriques, des capteurs inertiels ou des modèles physiques du canal, pourrait permettre d'améliorer davantage la précision globale.

Dans l'ensemble, les résultats obtenus confirment que l'architecture FCNN constitue une solution particulièrement adaptée aux applications de localisation souterraine. Sa capacité à maintenir des performances élevées dans des conditions variées démontre sa robustesse face aux fluctuations environnementales et aux dégradations du signal, deux facteurs critiques dans les milieux miniers réels. La cohérence des performances observées sur plusieurs jeux de données indépendants souligne ainsi le potentiel opérationnel de l'approche proposée et renforce la pertinence de l'utilisation de modèles d'apprentissage profond structurés pour la localisation radio dans les environnements miniers contraints.

Tableau 4
Comparaison des performances de localisation avec l'état de l'art

Référence	Environnement	Surface / Zone étudiée	Méthode	Résultat en m
RADAR	Bâtiment intérieur	≈ 980 m^2	RSSI + KNN	2,28 m
Horus	Bâtiment intérieur	≈ 600 m^2	RSSI probabiliste	1,95 m
FILA	Bâtiment intérieur	≈ 400 m^2	CSI Fingerprinting	1,79 m
ConFi (2017)	Bâtiment intérieur	282 m^2	CNN + CSI	1,37 m
Qiao et al. (2025)	Mine de charbon	Tunnel 100 × 5 m (500 m^2)	RSSI + Filtre de Kalman + localisation coopérative	1,55 m
Notre étude (Ancienne section)	Mine souterraine réelle	3 × 50 m (150 m^2)	FCNN + RSSI + CSI	RMSE(X)=0,174; RMSE(Y)=1,855
Notre étude (Nouvelle section)	Mine souterraine réelle	35 × 65 m (2275 m^2)	FCNN + RSSI + CSI	RMSE(X)=1,766 RMSE(Y)=1,836

4.6 Agrégation des données CSI avant l'apprentissage

Les résultats du pré-traitement (tableau 5) montrent que l'agrégation des échantillons CSI avant l'entrée dans le modèle conduit à des performances globalement inférieures à celles obtenues avec les stratégies de post-traitement. Lorsque l'information instantanée du canal est condensée en un seul échantillon représentatif, une partie de la variabilité locale du signal est perdue, ce qui limite la capacité du modèle à exploiter pleinement la richesse informationnelle du CSI.

Parmi les méthodes évaluées, la moyenne géométrique (*Geo-mean*) obtient la meilleure performance sur l'axe X avec un RMSE de 3.9584 m, tandis que la médiane donne le meilleur résultat sur l'axe Y avec un RMSE de 6.1205 m. La sélection aléatoire d'un seul échantillon produit les performances les plus faibles, avec des erreurs de 4.7057 m sur X et 7.4389 m sur Y, ce qui confirme qu'un seul instantané du canal ne représente pas suffisamment la variabilité du milieu.

Tableau 5 Performances de localisation obtenues avec les stratégies d'agrégation des échantillons CSI avant l'apprentissage

	Baseline	Mean (post)	Median	KDE	Geo-mean
RMSE X	1.8859	1.5243	1.3004	1.1746	1.4701
RMSE Y	2.1597	1.6699	1.4779	1.4657	1.4346

L'amélioration observée avec les méthodes statistiques (moyenne, médiane, moyenne géométrique) par rapport à la sélection aléatoire montre que l'agrégation permet de stabiliser partiellement l'information du canal. Toutefois, les erreurs restent nettement supérieures à celles obtenues par post-traitement, indiquant que l'agrégation en amont entraîne une perte d'information significative. Ces résultats suggèrent que la conservation de l'ensemble des observations CSI jusqu'à l'étape de prédiction constitue une stratégie plus efficace pour la localisation en environnement minier souterrain.

4.7 Agrégation des prédictions après inférence

Les résultats du pré-traitement (Tableau 6)montrent que l'agrégation des échantillons CSI avant l'entrée dans le modèle conduit à des performances globalement inférieures à celles obtenues avec les stratégies de post-traitement. Lorsque l'information instantanée du canal est condensée en un seul échantillon représentatif, une partie de la variabilité locale du signal est perdue, ce qui limite la capacité du modèle à exploiter pleinement la richesse informationnelle du CSI.

Parmi les méthodes évaluées, la moyenne géométrique (*Geo-mean*) obtient la meilleure performance sur l'axe X avec un RMSE de 3.9584 m, tandis que la médiane donne le meilleur résultat sur l'axe Y avec un RMSE de 6.1205 m. La sélection aléatoire d'un seul échantillon produit les performances les plus faibles, avec des erreurs de 4.7057 m sur X et 7.4389 m sur Y, ce qui confirme qu'un seul instantané du canal ne représente pas suffisamment la variabilité du milieu.

L'amélioration observée avec les méthodes statistiques (moyenne, médiane, moyenne géométrique) par rapport à la sélection aléatoire montre que l'agrégation permet de stabiliser partiellement l'information du canal. Toutefois, les erreurs restent nettement supérieures à celles obtenues par post-traitement, indiquant que l'agrégation en amont entraîne une perte d'information significative. Ces résultats suggèrent que la conservation de l'ensemble des observations CSI jusqu'à l'étape de prédiction constitue une stratégie plus efficace pour la localisation en environnement minier souterrain.

Tableau 6 Performances de localisation obtenues avant les stratégies d'agrégation des prédictions après inférence

	Random-select	Mean	Median	Geo-mean
RMSE X	4.7057	4.7107	4.0788	3.9584
RMSE Y	7.4389	6.8311	6.1205	6.3712

4.8 Conclusion

L'ensemble des résultats expérimentaux présentés dans ce chapitre met clairement en évidence la supériorité du modèle FCNN par rapport aux architectures MLP et LSTM pour la tâche de localisation souterraine basée sur les caractéristiques radio RSSI et CSI. Sur l'ensemble des métriques d'évaluation considérées — RMSE, MAE, coefficient de détermination R^2 et distributions CDF des erreurs — le FCNN obtient systématiquement les performances les plus élevées, traduisant une précision accrue, une dispersion d'erreur plus faible et une meilleure stabilité des prédictions spatiales. Ces résultats démontrent sa capacité à exploiter efficacement des vecteurs d'entrée de haute dimension tout en capturant les relations complexes et non linéaires caractéristiques de la propagation radio dans les environnements souterrains.

La robustesse du modèle est également confirmée lors de son évaluation sur de nouveaux jeux de données collectés dans un corridor distinct de la même mine, présentant une géométrie plus irrégulière et une proportion plus élevée de conditions de non-visibilité directe (NLOS). Malgré cette augmentation notable de la complexité environnementale, les performances restent élevées et cohérentes, ce qui constitue une preuve expérimentale solide de la capacité de généralisation du modèle. Cette propriété est essentielle pour toute application pratique, car elle garantit que le système peut être déployé dans des environnements réels présentant des caractéristiques différentes de celles observées lors de l'entraînement.

Le modèle MLP, quant à lui, conserve un rôle de référence méthodologique pertinent. Bien qu'il offre des performances globalement satisfaisantes, celles-ci demeurent inférieures à celles du FCNN, ce qui suggère que les architectures entièrement connectées simples présentent des limitations lorsqu'il s'agit d'exploiter la structure interne des données CSI. Néanmoins, sa stabilité et sa simplicité d'implémentation en font une solution *baseline* fiable pour l'évaluation comparative de méthodes plus avancées.

À l'inverse, le modèle LSTM se révèle moins adapté au problème étudié. Conçu principalement pour traiter des dépendances temporelles ou séquentielles, il ne

bénéficie pas pleinement de ses mécanismes internes dans un contexte où les mesures sont essentiellement indépendantes et où la dimension temporelle ne constitue pas une source d'information dominante. Ses performances inférieures indiquent que l'introduction d'une structure récurrente n'apporte pas d'avantage significatif pour la localisation fondée sur des signatures radio instantanées. Cette observation confirme que l'adéquation entre la nature des données et l'architecture du modèle constitue un facteur déterminant dans la conception de systèmes d'apprentissage automatique performants.

De manière générale, les analyses réalisées dans ce chapitre démontrent que l'architecture FCNN représente la solution la plus appropriée pour la localisation radio en milieu minier souterrain. Sa capacité à fournir des estimations précises, stables et généralisables dans des conditions de propagation complexes confirme son potentiel pour des applications réelles telles que le suivi d'équipements, la sécurité des travailleurs ou la navigation autonome en environnement souterrain.

CONCLUSION

La localisation en environnements souterrains constitue un défi scientifique majeur en raison de l'absence de systèmes de positionnement satellitaire, de la forte atténuation des signaux radio et de la complexité des phénomènes de propagation, dominés par les réflexions multiples, l'évanouissement et les conditions fréquentes de non-visibilité directe (NLOS). Dans ce contexte, le développement de solutions de localisation robustes, précises et adaptables représente un enjeu important pour les opérations minières, la robotique autonome et la sécurité des travailleurs.

Ce mémoire propose une approche de localisation basée sur l'exploitation conjointe des informations RSSI et CSI, combinée à l'utilisation de modèles d'apprentissage profond pour apprendre la relation non linéaire entre signatures radio et position spatiale dans un environnement minier réel. Contrairement aux approches conventionnelles fondées sur des modèles analytiques de propagation, souvent limitées par la variabilité du canal radio souterrain, l'approche proposée repose sur l'apprentissage direct des structures internes du canal, permettant une modélisation plus flexible et plus représentative des conditions réelles.

L'étude comparative entre trois architectures neuronales (FCNN, MLP et LSTM) a montré que le choix de l'architecture joue un rôle déterminant dans la qualité de la localisation. Les résultats ont démontré la supériorité du modèle FCNN, qui a obtenu les meilleures performances sur le jeu de données initial, avec des erreurs faibles et une forte corrélation entre positions réelles et positions estimées. Cette observation montre que, dans le contexte étudié, une architecture dense profonde est plus adaptée à l'exploitation des structures internes du CSI qu'un modèle purement séquentiel comme le LSTM ou plus simple comme le MLP.

Au-delà de la simple comparaison de modèles, la principale contribution de ce travail réside dans l'évaluation expérimentale de la capacité de généralisation du modèle dans un environnement souterrain distinct, caractérisé par une géométrie plus complexe et davantage de conditions NLOS. Les résultats obtenus sur ce second jeu de données montrent que le FCNN conserve une précision élevée malgré le

changement de corridor et des conditions de propagation. Cette stabilité constitue un résultat important, car elle démontre que le modèle ne se limite pas à mémoriser un environnement spécifique, mais qu'il apprend effectivement des caractéristiques généralisables du canal radio souterrain.

Une contribution complémentaire importante de ce mémoire concerne l'analyse de l'impact des stratégies d'agrégation des échantillons CSI. Les résultats ont montré que l'exploitation de multiples réalisations instantanées du canal, combinée à une agrégation appropriée des prédictions, permet d'améliorer significativement la précision de localisation. Cette observation met en évidence l'importance de la représentation statistique du canal dans les systèmes de localisation basés sur CSI et constitue un apport méthodologique pertinent pour les travaux futurs.

Ainsi, ce travail démontre que l'exploitation des structures internes du CSI à l'aide d'architectures adaptées constitue une approche efficace pour la localisation en environnement souterrain. Plus largement, il confirme que l'intégration de mesures radio fines avec des modèles d'apprentissage profond permet de dépasser certaines limitations des approches RSSI conventionnelles et d'ouvrir la voie à des systèmes de positionnement plus robustes et plus précis dans les environnements confinés

Cependant, plusieurs limites doivent être soulignées. D'une part, le modèle reste dépendant du site d'apprentissage, et ses performances peuvent être influencées par les caractéristiques géométriques et matérielles propres à chaque environnement souterrain. D'autre part, la variabilité intrinsèque du canal radio souterrain demeure un facteur de complexité important, susceptible d'affecter la stabilité des prédictions dans des conditions plus dynamiques (présence de véhicules, de personnes ou de changements environnementaux). Enfin, la campagne expérimentale repose sur un protocole d'acquisition contrôlé, ce qui limite encore la validation dans des conditions d'exploitation réalistes en pratique.

Dans la perspective de travaux futurs, une extension naturelle de cette recherche consiste à automatiser l'acquisition des mesures radiofréquences au moyen d'une plateforme robotique mobile telle que le robot *Seekur.* Une telle automatisation

permettrait d'améliorer la précision, la répétabilité et l'efficacité des campagnes de mesure, tout en facilitant l'intégration en temps réel des données dans un jumeau numérique du milieu souterrain. Cette évolution ouvrirait la voie à la génération dynamique de cartes radiofréquences et au développement de systèmes intelligents de supervision, de localisation et d'optimisation des communications minières.

Enfin, ce mémoire apporte une contribution expérimentale et méthodologique au domaine de la localisation sans fil en milieux confinés. Il montre que la combinaison du CSI et de modèles d'apprentissage profond adaptés constitue une voie prometteuse pour concevoir des systèmes de localisation précis, robustes et généralisables, répondant aux exigences croissantes des environnements souterrains intelligents.

ANNEXE A – EXEMPLE D'UN PAQUET CSI

MAC: 40:22: D8:03:C8:45 | INV: 1 | RSSI: −22 dBm | CSI Length: 128

CSI Data (I, Q par sous-porteuse)

0:(−118,32) 1:(8,0) 2:(0,0) 3:(0,0) 4:(0,0) 5:(−2,4) 6:(−7,18) 7:(−7,18)

8:(−8,18) 9:(−8,17) 10:(−8,17) 11:(−9,17) 12:(−10,16) 13:(−10,16)

14:(−10,16) 15:(−11,16) 16:(−11,15) 17:(−11,15) 18:(−11,14)

19:(−11,14) 20:(−11,14) 21:(−11,14) 22:(−11,13) 23:(−11,13)

24:(−11,13) 25:(−11,13) 26:(−10,13) 27:(−10,13) 28:(−10,13)

29:(−10,13) 30:(−9,13) 31:(−9,13) 32:(−5,6) 33:(−9,12) 34:(−8,12)

35:(−8,12) 36:(−8,12) 37:(−8,12) 38:(−8,12) 39:(−7,13) 40:(−7,13)

41:(−7,12) 42:(−7,13) 43:(−7,13) 44:(−6,13) 45:(−6,13) 46:(−6,13)

47:(−5,14) 48:(−5,14) 49:(−5,14) 50:(−5,14) 51:(−5,14) 52:(−5,14)

53:(−4,15) 54:(−4,15) 55:(−4,15) 56:(−4,15) 57:(−4,15) 58:(−4,15)

59:(−1,3) 60:(0,0) 61:(0,0) 62:(0,0) 63:(0,0)

APPENDICE A – LISTE DES PUBLICATIONS

Cette section présente les publications scientifiques effectuées dans le cadre du programme de maitrise, incluant les articles soumis, acceptés et publiés dans des revues avec comité de lecture et conférences.

[1] H. Zgheib, N. Kandil, and N. Hakem. “Assessment Of Neural Networks Localization Using RSSI & CSI “, 2025 IEEE INC-USNCURSI Radio Science Meeting (Joint with AP-S Symposium),

[2] H. Zgheib, N. Kandil, and N. Hakem, “Experimental Analysis of CSI and RSSI for Deep Learning Localization in Underground Mine Tunnels,” in Proc. EuCAP, 2026.

[3] H. Zgheib, N. Kandil, and N. Hakem. “FCNN Localization Performance Across Different Underground Mine Sections CSI “, 2026 IEEE INC-USNCURSI Radio Science Meeting (Joint with AP-S Symposium),

LISTE DE RÉFÉRENCES

[1] U. S. Toro *et al.*, "A survey of data mining techniques for indoor localization," *International Journal of Engineering and Manufacturing*, vol. 11, no. 6, p. 19, 2021.

[2] J. Baek, J. Park, S. Cho, et C. Lee, "3D global localization in the underground mine environment using mobile LiDAR mapping and point cloud registration," *Sensors*, vol. 22, no. 8, p. 2873, 2022.

[3] H. Liu *et al.*, "A review of positioning technologies for personnel and equipment in underground mines," *International Journal of Digital Earth*, vol. 18, no. 1, p. 2506493, 2025.

[4] M. El-Absi, F. Zheng, A. Abuelhaija, A. Al-haj Abbas, K. Solbach, et T. Kaiser, "Indoor large-scale MIMO-based RSSI localization with low-complexity RFID infrastructure," *Sensors*, vol. 20, no. 14, p. 3933, 2020.

[5] A. Sobehy, É. Renault, et P. Mühlethaler, "Generalization aspect of accurate machine learning models for CSI-based localization," *Annals of Telecommunications*, vol. 77, no. 5, pp. 345-357, 2022.

[6] H. Lee, W. Wan Aris, T. Musa, A. Sha'ameri, W. Ooi, et A. Ahmad, "GPS continuously operating reference station (cors) selection towards regional gps orbit determination: a simulated study using trilateration technique," *Jurnal Teknologi*, vol. 85, no. 1, pp. 99-105, 2022.

[7] H. S. Fahama, K. Ansari-Asl, Y. S. Kavian, et M. N. Soorki, "An experimental comparison of RSSI-based indoor localization techniques using ZigBee technology," *IEEE Access*, vol. 11, pp. 87985-87996, 2023.

[8] J. Fontaine, B. Van Herbruggen, A. Shahid, S. Kram, M. Stahlke, et E. De Poorter, "Ultra wideband (UWB) localization using active CIR-based fingerprinting," *IEEE Communications Letters*, vol. 27, no. 5, pp. 1322-1326, 2023.

[9] Q. Ye *et al.*, "EdgeLoc: A robust and real-time localization system toward heterogeneous IoT devices," *IEEE Internet of Things Journal*, vol. 9, no. 5, pp. 3865-3876, 2021.

[10] R. Shahbazian, G. Macrina, E. Scalzo, et F. Guerriero, "Machine learning assists IoT localization: A review of current challenges and future trends," *Sensors*, vol. 23, no. 7, p. 3551, 2023.

[11] H. Attar *et al.*, "Machine learning in indoor localization prediction using Received Signal Strength Indicator and Wi-Fi network," *International Journal of Intelligent Networks*, vol. 6, pp. 233-243, 2025/01/01/ 2025. doi: https://doi.org/10.1016/j.ijin.2025.10.001.

[12] Z. Yang, Z. Zhou, et Y. Liu, "From RSSI to CSI: Indoor localization via channel response," *ACM Comput. Surv.*, vol. 46, no. 2, p. Article 25, 2013. doi: 10.1145/2543581.2543592.

[13] X. Qiao, F. Chang, J. Wang, X. Wang, et Y. Jiang, "Coal mine underground positioning algorithm based on RSSI model correction and node cooperation," *Archives of Mining Sciences*, vol. 70, no. 1, 2025.

[14] A. S. Saif, S. Akib, M. A. S. Khan, A. M. Hadi, R. P. Karmoker, et J. J. Gomes, "Aggressive action estimation: a comprehensive review on neural

network based human segmentation and action recognition," *International journal of education and management engineering*, no. 1, pp. 9-19, 2019.
[15] I. H. Sarker, "Machine learning: Algorithms, real-world applications and research directions," *SN computer science*, vol. 2, no. 3, pp. 1-21, 2021.
[16] S. S. Basha, S. R. Dubey, V. Pulabaigari, et S. Mukherjee, "Impact of fully connected layers on performance of convolutional neural networks for image classification," *Neurocomputing*, vol. 378, pp. 112-119, 2020.
[17] X. Shen *et al.*, "Deepmad: Mathematical architecture design for deep convolutional neural network," Dans *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2023, pp. 6163-6173.
[18] H. Chen, Y. Zhang, W. Li, X. Tao, et P. Zhang, "ConFi: Convolutional neural networks based indoor Wi-Fi localization using channel state information," *Ieee Access*, vol. 5, pp. 18066-18074, 2017.
[19] K. Zhou, S.-K. Oh, J. Qiu, W. Pedrycz, K. Seo, et J. H. Yoon, "Design of hierarchical neural networks using deep LSTM and self-organizing dynamical fuzzy-neural network architecture," *IEEE Transactions on Fuzzy Systems*, vol. 32, no. 5, pp. 2915-2929, 2024.
[20] Y. Yu, X. Si, C. Hu, et J. Zhang, "A review of recurrent neural networks: LSTM cells and network architectures," *Neural computation*, vol. 31, no. 7, pp. 1235-1270, 2019.
[21] D.-F. B. Moukodouma, C. Denis, D. R. R. Mbourou, et C. A. Nkoulembene, "Comparaison des modèles lstm et transformée en ondelettes-lstm pour la prédiction de la température dans une partie du bassin du congo," *International Journal of Innovation and Applied Studies*, vol. 44, no. 1, pp. 77-94, 2024.
[22] R. Ayyalasomayajula *et al.*, "Deep learning based wireless localization for indoor navigation," Dans *Proceedings of the 26th Annual International Conference on Mobile Computing and Networking*, 2020, pp. 1-14.
[23] T. S. Rappaport, *Wireless communications: Principles and practice, 2/E*: Pearson Education India, 2010.
[24] Y.-s. You, L.-j. Jing, Q.-h. Yang, et Z. Shen, "Analysis and modeling of radio propagation fading characteristics in tunnel construction," *Heliyon*, vol. 10, no. 4, 2024.
[25] A. Khalaf, N. Hakem, et N. Kandil, "CSI-Based Model for Precision Localization in Underground Mines," Dans *2024 IEEE INC-USNC-URSI Radio Science Meeting (Joint with AP-S Symposium)*, 2024, pp. 443-444: IEEE.
[26] G. M. C. Barajas, P. D. Córdoba, U. T. M. Sánchez, F. d. J. I. Martínez, E. V. Moreno, et V. H. R. Contreras, "TECHNICAL MANUAL,"
[27] R. Pi, "Model B datasheet," *Raspberry Pi Foundation. Pencoed, Wales. Available online: https://www. raspberrypi. com/products/raspberry-pi-4-model-b/(accessed on 18 January 2024)*,
[28] T. O. Hodson, "Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not," *Geoscientific Model Development Discussions*, vol. 2022, pp. 1-10, 2022.

[29] H. A. Ounifi, "Modélisation, analyse et prédiction de l’efficacité énergétique des centres de données," École de technologie supérieure, 2021.
[30] D. C. Montgomery, E. A. Peck, et G. G. Vining, *Introduction to linear regression analysis*: John Wiley & Sons, 2021.
[31] a. N. H. Nahi. Kandil. Hussam. Zgheib, "FCNN Localization Performance Across Different Underground Mine Sections CSI " présenté à IEEE INC-USNCURSI Radio Science Meeting

2025.