



République algérienne démocratique et populaire
Ministère de l'enseignement supérieur et de la recherche scientifique
Université de Mohamed El-Bachir El-Ibrahimi - Bordj Bou Arreridj
Institut d'Electronique et de Télécommunication

Rapport de projet de fin d'études

Pour obtenir

LE DIPLOME DE MASTER

Filière : TELECOMMUNICATION

Spécialité : Systèmes TELECOMMUNICATION

Réalisé par :

BOUCHAKOUR ASSIA

Thème :

**Localisation basée sur l'UWB améliorée par
l'apprentissage supervisé**

Soutenu le : 28 juin 2026

Devant le Jury composé de :

<i>Nom & Prénom</i>	<i>Grade</i>	<i>Qualité</i>	<i>Etablissement</i>
<i>Mme. FENENICHE Wafa</i>	<i>MCB</i>	<i>Président</i>	<i>Univ-BBA</i>
<i>M. BOUSSAHOUL Abdlekrim</i>	<i>MAA</i>	<i>Encadreur</i>	<i>Univ-BBA</i>
<i>Mme. MELIZI Nora</i>	<i>MAA</i>	<i>Examineur</i>	<i>Univ-BBA</i>

Année Universitaire 2025/2026

Remerciements

Je souhaite tout d'abord remercier les enseignants et l'équipe pédagogique de l'Université Mohamed El Bachir El Ibrahimi pour la formation reçue durant mon parcours universitaire.

Ce travail a été réalisé sous la direction de Monsieur *Abdelkrim Boussahoul*. Je le remercie pour son encadrement, sa disponibilité et la pertinence de ses conseils. Son soutien et ses remarques constructives m'ont permis d'avancer sereinement et de mener cette étude à son terme. J'ai particulièrement apprécié les connaissances et l'expérience qu'il a partagées avec moi.

Mes remerciements s'adressent également aux membres du jury qui ont accepté d'examiner ce mémoire et de porter un intérêt à mes recherches.

Enfin, je remercie ma famille, mes amis et toutes les personnes qui m'ont accompagné et encouragé durant l'élaboration de ce projet.

Dédicace

Je dédie ce modeste travail, fruit de longues années d'études et de persévérance, à :

Mes chers parents :

Mon tendre père, pour ses sacrifices, ses précieux conseils et son soutien indéfectible qui ont fait de moi ce que je suis aujourd'hui.

Ma douce mère:

pour son amour inconditionnel, sa patience infinie et ses prières qui m'ont toujours éclairé le chemin de la réussite. Que Dieu leur accorde santé, bonheur et longue vie.

Mes frères et sœurs :

Pour leur affection, leurs encouragements constants et leur présence rassurante à mes côtés.

À toute ma famille:

Proches et lointains, pour leur soutien moral et leur fierté partagée.

Mes fidèles amis :

Qui ont partagé avec moi les moments de doute et de joie, et avec qui j'ai lié des liens d'amitié sincères et durables tout au long de mon parcours universitaire.

Mes respectueux enseignants :

Qui m'ont transmis le savoir avec dévouement et générosité.

À tous ceux qui portent une lueur d'espoir pour mon avenir, je dédie ce travail.

Résumé

Cette mémoire s'intéresse à l'amélioration de la précision de la localisation en environnement intérieur (Indoor), un domaine où le système GPS standard s'avère inefficace. L'objectif principal de ce travail est de concevoir un système d'estimation de trajectoires pour des objets mobiles ou fixes en s'appuyant sur la technologie Ultra-Wideband (UWB). Bien que l'UWB offre une excellente résolution temporelle, ses performances restent fortement dégradées par les phénomènes de multi-trajets et la non-linéarité des signaux en présence de bruit. Pour pallier ces limites, nous proposons l'intégration d'algorithmes d'apprentissage supervisé issus de l'intelligence artificielle. Après une étude comparative des techniques géométriques classiques telles que le TOA et le TDOA, nous avons implémenté et simulé une approche intelligente. Les résultats de simulation obtenus démontrent la capacité des modèles entraînés à corriger les erreurs de mesure et à prédire avec précision les coordonnées tridimensionnelles (X, Y, Z) des cibles. Cette approche hybride surpasse les méthodes traditionnelles en termes de robustesse face aux environnements non-linéaires complexes.

Pour surmonter ces défis, ce travail propose une approche intelligente basée sur l'intégration des algorithmes d'apprentissage supervisé (Intelligence Artificielle). L'objectif principal est de modéliser et de corriger ces perturbations non linéaires afin de prédire avec exactitude les paramètres de positionnement. La phase pratique et méthodologique de cette étude a été entièrement développée et simulée sous l'environnement **Matlab**. Elle englobe l'implémentation des algorithmes, l'étape d'apprentissage rigoureuse dédiée à la mise à jour des coefficients de pondération (les poids du réseau), ainsi que la reconstruction des trajectoires. Les résultats de simulation, validés par l'analyse des courbes d'estimation des coordonnées tridimensionnelles (X, Y, Z) pour différents points de test, démontrent une nette supériorité en termes de précision, une réduction significative de l'erreur quadratique moyenne, et une robustesse accrue face aux bruits de mesure par rapport aux méthodes conventionnelles.

Abstract

This thesis focuses on optimizing and enhancing the precision of indoor localization systems, a critical domain for mobile object tracking where conventional GPS systems fail due to the severe attenuation of satellite signals through building structures. To address this limitation, Ultra-Wideband (UWB) technology is deployed as a promising alternative, leveraging its high

time resolution and material penetration capabilities. However, in complex indoor environments, UWB performance severely degrades due to non-line-of-sight (NLOS) multi-path propagation and ambient noise. These factors introduce highly non-linear measurement errors—specifically affecting Time of Arrival (TOA) and Time Difference of Arrival (TDOA) methods—making classical geometric trajectory estimation unreliable.

To overcome these challenges, this work proposes an intelligent approach based on incorporating supervised learning algorithms (Artificial Intelligence). The primary objective is to model and mitigate these non-linear disturbances, thereby enabling precise prediction of positioning parameters. The practical and methodological phase of this research was fully developed and simulated within the **Matlab** environment. This process involved algorithm implementation, a rigorous training phase focused on updating synaptic weights (weighting coefficients), and trajectory reconstruction. The simulation results, validated through the analysis of estimation curves for three-dimensional coordinates (X, Y, Z) across various test points, demonstrate superior performance. The proposed supervised learning framework achieves a significant reduction in root-mean-square error (RMSE) and exhibits enhanced robustness against non-linear noise compared to traditional geometric localization techniques.

المخلص

تتمحور هذه الأطروحة حول تحسين ورفع دقة أنظمة تحديد المواقع داخل المباني (**Indoor Localization**)، وهو مجال حيوي ومحوري لتتبع الأجسام المتحركة والثابتة في بيئات تفتقر فيها أنظمة تحديد المواقع العالمية التقليدية (**GPS**) إلى الفعالية نتيجة للتوهج الشديد والإشارات المحجوبة بواسطة الجدران والمسقفات. وكبديل واعد، تم الاعتماد على تقنية النطاق العريض للغاية (**UWB**) نظراً لما تتمتع بكفاءة زمنية فائقة وقدرة عالية على اختراق العوائق. ومع ذلك، فإن كفاءة هذه التقنية تواجه تدهوراً حاداً في البيئات الداخلية المعقدة نتيجة لظاهرة تعدد المسارات غير المباشرة (**NLOS**) والضوضاء المحيطة، مما يولد أخطاء قياس معقدة وغير خطية تؤثر مباشرة على طرق حساب زمن الوصول (**TOA**) وفارق زمن الوصول (**TDOA**)، ويجعل من الصعب تحديد المسارات بالطرق الهندسة التقليدية.

مواجهة هذه العقبات، يقدم هذا البحث نهجاً ذكياً يركز على دمج خوارزميات التعلم المشرف (الذكاء الاصطناعي). يكمن الهدف الأساسي في نمذجة وتصحيح هذه التشوهات اللاخطية للتنبؤ بدقة عالية بمعاملات الموقع وإحداثيات الأجسام. وقد تم تنفيذ الجانب التطبيقي والمنهجي لهذا العمل بالكامل ومحاكاته في بيئة البرمجة **Matlab**، حيث شمل البرنامج صياغة الخوارزميات، وتطبيق مرحلة تدريب دقيقة ومكثفة لتحديث معاملات الأوزان وقيم التوزين للنموذج، ومن ثم إعادة بناء المحاكاة للمسارات. أظهرت نتائج المحاكاة، والتي تم التحقق منها عبر تحليل منحنيات تقدير الإحداثيات ثلاثية

Résumé

الأبعاد (X, Y, Z) واختبار نقاط مختلفة، تفوقاً واضحاً للنموذج المقترح. حيث حقق خفضاً كبيراً في معدل الخطأ وتقليصاً لنسبة الضوضاء، مع إبداء مرونة عالية في التعامل مع الحالات اللاخطية مقارنة بالتقنيات الحسابية التقليدية.

Sommaire

Table de matière:

<i>Remerciements</i>	<i>ii</i>
<i>Dédicace</i>	<i>iii</i>
<i>Résumé</i>	<i>iv</i>
<i>Abstract</i>	<i>iv</i>
<i>Table de matière:</i>	<i>ix</i>
<i>Liste des figures :</i>	<i>xiii</i>
<i>Liste des tableaux :</i>	<i>xiv</i>
Introduction Générale :	Erreur ! Signet non défini.

chapitre I: Les systèmes de localisation Indoor(UWB)

I.1. Introduction	3
I.2 Définition Les Systèmes de Localisation Outdoor (GPS)	4
I.3 caractéristiques générales de Systèmes GPS localisation Outdoor	4
I.3.1 Masquage des signaux et indisponibilité (Blocked Signals)	5
I.3.2 Phénomène de multi-trajets (Multipath)	5
I.3.3 Réflexions non directes (Non-Line-of-Sight - NLOS)	5
I.3.4 Atténuation du rapport signal sur bruit (C/N0)	6
I.4. Les systèmes de localisation indoor	6
I.4.1 La complexité du terminal	6
I.4.2. La complexité de l'infrastructure	7
I.4.3 La précision / performance	7
I.4.4. La disponibilité / continuité	7
I.4.5. L'intégrité	7
I.5. Définition et Caractéristiques des signaux UWB	7
I.5.1. Définition des signaux UWB	7
I.5.2 Caractéristiques des signaux UWB	8
I.6. Problèmes et inconvénients des systèmes UWB (Erreurs, Bruit, Multi-Trajets) :	9
I.6.1 Le phénomène de multi-trajets (Multipath)	9

I.6.2 Les erreurs de mesure et le bruit	10
I.6.3 Conditions Non-Line-of-Sight (NLoS)	11
I.7. Les différentes techniques de localisation basées sur les méthodes TOA et TDOA	12
I.7.1 La technique Time of Arrival (TOA)	12
I.7.2. La technique Time Difference of Arrival (TDOA).....	13
I.8. Avantages et inconvénients de chaque méthode.....	13
I.8.1. Avantages et inconvénients de la méthode TOA	14
I.8.1 Avantages et inconvénients de la méthode TDOA	14
I.9 Les difficultés de détermination de la trajectoire dans systèmes non linéaire ..	16
I.10. Conclusion	16

chapitre II: Apprentissage Supervisé

II.1. Introduction	18
II.2 L'Intelligence Artificielle	18
II.3 Types d'Apprentissage en Intelligence Artificielle	19
II.3.1 Apprentissage Supervisé	19
II.3.2 Apprentissage Non Supervisé	19
II.3.3 Apprentissage par Renforcement.....	19
II.4 Techniques d'Apprentissage Supervisé pour la Localisation UWB	19
II.4.1 Méthodes Classiques	19
II.4.2 Réseaux de Neurones Artificiels.....	20
II.4.3 Méthodes d'Ensemble et Avancées.....	21
II.5 Application des Algorithmes d'Apprentissage Supervisé aux Systèmes UWB	24
II.5.1 Classification LOS/NLOS	24
II.5.2 Correction des Erreurs de Distance	24
II.5.3 Estimation Directe des Coordonnées	24
II.5.4 Prédiction des Trajectoires	25
II.6 Avantages de l'Apprentissage Supervisé par Rapport aux Techniques Traditionnelles	25
II.7 Défis et Limitations	26

II.8 Conclusion	26
-----------------------	----

chapitre III: Implémentation et résultats de simulation

III.1. Introduction	26
III.2 Présentation des Algorithmes	26
III.2.1 Architecture du Réseau de Neurones	26
III.2.2 Division des Données	30
III.2.3 : Données d'Entrée et de Sortie	30
III.3 Étapes d'Apprentissage	31
III.3.1 Préparation des Données	31
III.3.2 Processus d'Apprentissage	31
III.3.3 Prédiction et Correction	32
III.4 Simulation avec MATLAB	32
III.4.1 Environnement de Simulation	32
III.4.2 Description de la Méthodologie	32
III.5 Présentation des Courbes d'Estimation	33
III.5.1 Trajectoire de l'Objet 1	33
III.5.2 Trajectoire de l'Objet 2	34
III.5.3 Trajectoire de l'Objet 3	35
III.5.4 Trajectoire de l'Objet 4 (Sinusoïdale)	35
III.5.5 Trajectoire de l'Objet 5 (Linéaire)	36
III.6 Analyse des Performances	37
III.6.1 Métriques d'Évaluation	37
III.6.2 Récapitulatif des Performances	38
III.6.3 Histogramme des Erreurs	39
III.6.4 Analyse de Régression.....	40
III.7 Discussion des Résultats	41
3.7.1 Comparaison des Approches	41
III.7.2 Interprétation Physique.....	41
III.7.3 Limites et Perspectives.....	42
III.8 Conclusion	42

Conclusion Général	Erreur ! Signet non défini.
Liste des références	48

Liste des figures

Figure I.1 :Schéma de principe de la localisation par GPS (trilatération spatiale).....	4
Figure I.2 : Illustration des concepts de ligne de visée (Line-of-Sight - LOS) et de non-ligne de visée (Non-Line-of-Sight - NLOS) pour la localisation GNSS en milieu urbain	6
Figure III.1 : les résultats d'estimation de la trajectoire pour le premier objet mobile.....	33
Figure III.2 : les résultats pour le deuxième objet.	34
Figure III.3 : les résultats pour le troisième objet.	35
Figure III.4 : présente les résultats pour le quatrième objet.....	36
Figure III.5 : présente les résultats pour le cinquième objet.	37
Figure III.6 : Résultats du training du réseau de neurones	40
Figure III.7 : courbe de performances comparées	40
Figure III.8 : l'histogramme des erreurs de localisation pour les trois approches comparées.....	41
Figure III.9 : les diagrammes de régression entre les coordonnées estimées et42 les coordonnées réelles pour chaque approche	42
Figure III.10 : Diagrammes de régression entre les sorties prédites par le réseau de neurones et les cibles réelles	42

Liste des tableaux

Tableaux II.1 : Avantages de l'Apprentissage Supervisé par Rapport aux Techniques	
Traditionnelles	23
Tableau III.1 : Nombre de paramètres Le réseau comporte	
28	
Tableau III.2 Paramètres de l'algorithme d'apprentissage.....	29
Tableau III.3 : les trois sous-ensembles de la base de données	
30	
Tableau III.4: Métriques de performance comparées pour les trois objets	
39	

Introduction générale

Introduction générale

Ce projet vise à améliorer la précision de la localisation d'objets à l'intérieur des bâtiments, les systèmes UWB sont réputés pour leur efficacité, leurs performances diminuent souvent à cause du bruit de mesure et des phénomènes de trajets multiples. L'objectif est donc d'utiliser des modèles d'apprentissage pour mieux établir le lien entre les signaux reçus et la position réelle des objets, afin de réduire ces erreurs. Le travail consiste d'abord à analyser les sources de perturbation du signal UWB, puis à développer et tester des algorithmes capables de corriger les trajectoires. Les résultats seront validés par des simulations sous Matlab ou Python et comparés aux méthodes de localisation habituelles. [1]

La technologie Ultra Wide Band, ou UWB, est une solution efficace pour localiser des objets à l'intérieur des bâtiments. Son principal intérêt réside dans l'utilisation d'impulsions radio très brèves sur une large bande de fréquences, ce qui permet de mesurer avec précision le temps de propagation des signaux. [1]

Dans les espaces intérieurs, les signaux radio subissent souvent des phénomènes de multi-trajets à cause des rebonds sur les murs, les meubles ou les plafonds. Contrairement au Wi-Fi ou au GSM, l'UWB parvient à distinguer ces différents trajets grâce à sa grande résolution temporelle. Cette capacité améliore nettement l'estimation de la position des objets et limite les erreurs de localisation. [3]

L'UWB résiste également bien aux interférences et permet d'obtenir une précision de l'ordre de quelques centimètres. Ces performances rendent cette technologie adaptée au suivi d'objets, à la navigation intérieure, à la robotique mobile et aux besoins industriels nécessitant un positionnement précis en temps réel.

L'intérêt majeur de l'UWB tient à sa capacité à fournir des mesures de distance fiables dans des environnements complexes où les techniques traditionnelles rencontrent des limites. Cette technologie constitue donc une option solide pour les futurs systèmes de localisation à l'intérieur des bâtiments. [1]

Dans le domaine de la perception robotique et de la navigation autonome, l'estimation des trajectoires des objets fixes et mobiles repose sur l'intelligence artificielle, L'analyse d'un

environnement dynamique demande d'abord de distinguer le mouvement du capteur, appelé ego-motion, du mouvement réel des objets environnants. Des algorithmes de compensation globale servent à stabiliser l'arrière-plan pour identifier les structures fixes. Pour le suivi des éléments mobiles, qu'ils soient rigides comme des véhicules ou non rigides comme des piétons, on utilise des estimateurs stochastiques tels que le filtre de Kalman pour corriger et prédire leur état cinématique. L'apprentissage supervisé complète ce dispositif. L'extraction de caractéristiques visuelles, telles que la couleur et la texture, permet à des classifieurs comme les machines à vecteurs de support (SVM), AdaBoost ou les K-plus proches voisins (KNN) de réaliser une segmentation sémantique de la scène. Cela aide à différencier les zones navigables des obstacles et à reconnaître des trajectoires types pour anticiper le comportement futur des objets dans l'espace. [2] [3]

Le présent mémoire est structuré autour de trois chapitres.

- Le premier chapitre est consacré aux concepts de base des systèmes de localisation Indoor et Outdoor et leurs caractéristiques. Nous continuons avec la technologie UWB définition, caractéristique, ses avantages et ses inconvénients et nous terminons en présentant les deux techniques de l'estimation de paramètres TOA et TDOA.
- Dans le deuxième chapitre présente une étude détaillée de l'apprentissage supervisé, ainsi que les différents algorithmes et techniques utilisés dans l'estimation et la prédiction des paramètres.
- Le dernier chapitre présente les résultats de l'implémentation des algorithmes l'apprentissage supervisé et la discussion des résultats de simulations qui présente l'efficacité de cette méthode.

Nous terminons par une conclusion générale

Chapitre I:
Les systèmes de localisation Indoor(UWB)

I.1. Introduction :

Les avancées technologiques récentes ont profondément modifié les méthodes de navigation dans les espaces intérieurs. Autrefois, les individus s'appuyaient sur des cartes papier, des boussoles ou des repères visuels naturels et architecturaux pour se repérer. Aujourd'hui, les smartphones et les technologies de positionnement facilitent considérablement ces déplacements. Le système de positionnement global (GPS), intégré aux systèmes GNSS, est devenu un outil courant pour la navigation extérieure. Cependant, malgré son efficacité dans les espaces ouverts, le GPS rencontre des limites importantes en intérieur. Les signaux satellites sont atténués, réfléchis ou bloqués par les murs et autres structures, rendant la localisation imprécise voire impossible. Ce problème est particulièrement marqué dans des environnements complexes comme les centres commerciaux, les hôpitaux, les aéroports ou les grands établissements universitaires, où les utilisateurs ont souvent du mal à s'orienter ou à trouver un lieu précis. Pour répondre à cette difficulté, les recherches se sont orientées vers le développement de systèmes de positionnement intérieur (Indoor Positioning Systems, IPS), utilisant des technologies sans fil à courte ou moyenne portée telles que le Wi-Fi, le Bluetooth Low Energy (BLE), la RFID, les ultrasons ou l'Ultra-Wideband (UWB). Parmi ces technologies, l'UWB retient l'attention en raison de ses performances pour le positionnement intérieur. Elle fonctionne par l'émission d'impulsions radio de faible puissance sur une bande passante large (plus de 500 MHz). Cette caractéristique lui permet de traverser les obstacles et diminuer les effets des réflexions, tout en offrant un temps de latence réduit. En mesurant avec précision le temps de vol (Time of Flight, ToF) des signaux, l'UWB peut atteindre une précision de localisation à l'échelle du centimètre, avec une marge d'erreur située entre 10 et 20 cm. Cette précision dépasse celle des technologies concurrentes comme le Wi-Fi ou le Bluetooth. [1]

Ce travail vise à concevoir un système de navigation intérieure précis, fiable et économique. Pour réduire les coûts tout en assurant de bonnes performances, le système utilise des technologies open source et des composants accessibles. L'architecture matérielle repose sur des modules ESP32 UWB DW1000, configurés comme ancres fixes et tags mobiles, tandis que le logiciel prend la forme d'une application mobile connectée via Wi-Fi et MQTT. Le calcul de position repose principalement sur la trilatération, accompagnée d'algorithmes de filtrage,

notamment le filtre de Kalman, pour améliorer la qualité des mesures. L'objectif est de fournir une solution capable d'assurer une navigation fluide, précise et en temps réel dans des environnements intérieurs complexes.

I.2 Définition Les Systèmes de Localisation Outdoor (GPS) :

Le GPS est aujourd'hui la technologie la plus aboutie pour localiser des objets ou des personnes en extérieur. Le système fonctionne grâce à un réseau de satellites en orbite qui envoient des signaux radio synchronisés vers la Terre. Un récepteur au sol capte ces informations pour calculer sa position exacte en latitude, longitude et altitude, tout en synchronisant l'heure. Ce calcul utilise la méthode de la trilatération et nécessite de recevoir simultanément les signaux d'au moins quatre satellites. Si cette solution est très efficace à ciel ouvert, elle perd en précision dans les milieux fermés ou les zones urbaines denses, car les signaux sont alors perturbés par des obstacles. C'est pour cette raison que d'autres technologies sont nécessaires pour assurer la localisation à l'intérieur des bâtiments. [4]




Figure I.1 :Schéma de principe de la localisation par GPS (trilatération spatiale) [5]

I.3 caractéristiques générales de Systèmes GPS localisation Outdoor

Dans les zones urbaines denses, souvent appelées canyons urbains, le fonctionnement normal du GPS est fortement perturbé par des effets géométriques et physiques. Les études réalisées par l'IFSTTAR décrivent ces phénomènes en précisant les caractéristiques suivantes [1]:

I.3.1 Masquage des signaux et indisponibilité (BlockedSignals) :

Dans les zones urbaines denses, les immeubles élevés et autres infrastructures forment des obstacles physiques qui bloquent la vue directe entre le récepteur au sol et les satellites. Cela réduit considérablement le nombre de satellites visibles. Quand il y a moins de quatre satellites en vue, il devient impossible de calculer la position par trilatération, ce qui cause des interruptions totales ou partielles du service de positionnement.

I.3.2 Phénomène de multi-trajets (Multipath) :

Le phénomène de multi-trajets se produit lorsque le signal radiofréquence émis par un satellite est réfléchi par des surfaces proches, comme des façades en verre ou en béton, ou des structures métalliques, avant d'atteindre l'antenne. Le récepteur capte alors plusieurs copies du même signal avec des délais différents. Cette superposition modifie le signal original et introduit des erreurs dans l'estimation des pseudo-distances, ce qui affecte directement la précision de la localisation finale.

I.3.3 Réflexions non directes (Non-Line-of-Sight - NLOS) :

Les réflexions non directes, ou situation NLOS (Non-Line-of-Sight), posent un problème plus important pour la localisation en milieu urbain extérieur. Ici, le signal direct est complètement bloqué par un obstacle, et le récepteur ne reçoit qu'un signal réfléchi. Comme la mesure du temps de propagation repose sur la vitesse de la lumière, la distance calculée est faussée, ce qui entraîne des erreurs importantes dans le positionnement et modifie considérablement la trajectoire estimée.[2]




Figure I.2 : Illustration des concepts de ligne de visée (Line-of-Sight - LOS) et de non-ligne de visée (Non-Line-of-Sight - NLOS) pour la localisation GNSS en milieu urbain. [7]

I.3.4 Atténuation du rapport signal sur bruit (C/N_0) :

L'atténuation du rapport signal sur bruit, noté (C/N_0), concerne la faiblesse intrinsèque du signal GPS reçu au sol. Dans des environnements extérieurs complexes, avec des arbres, du mobilier urbain ou des obstacles proches, le signal perd en puissance. Cette baisse du rapport (C/N_0) nuit aux boucles de poursuite du récepteur, ce qui le rend sensible aux interruptions de phase et limite la stabilité et la fiabilité globale de la localisation.[8].

I.4. Les systèmes de localisation indoor

Dans le cadre scientifique et technique de ce livre, les systèmes de localisation en intérieur sont des solutions destinées à fonctionner dans des espaces fermés. Dans ces lieux, les signaux des systèmes de navigation par satellite habituels, comme le GNSS ou le GPS, ne passent pas à cause de l'affaiblissement provoqué par les plafonds et les murs. Ces systèmes se distinguent et se classent selon plusieurs critères et variables clés qui sont expliqués dans le document : [9]

I.4.1. La complexité du terminal :

La complexité du terminal correspond au coût nécessaire pour intégrer le système dans l'appareil de l'utilisateur. Certaines solutions se distinguent parce qu'elles peuvent s'intégrer sous forme d'algorithme logiciel sur un terminal existant, comme un smartphone. En revanche,

d'autres systèmes exigent le développement de matériel spécifique, comme des antennes ou des fonctionnalités matérielles nouvelles.

I.4.2. La complexité de l'infrastructure :

La complexité de l'infrastructure mesure si le système demande la mise en place d'une infrastructure propre dans un bâtiment, comme c'est le cas avec les systèmes Ultra-Wideband (UWB) ou les pseudolites. Certains systèmes fonctionnent avec une infrastructure déjà en place, comme les réseaux Wi-Fi, Bluetooth ou Zigbee, tandis que d'autres n'en ont pas besoin, tels que les systèmes inertiels ou optiques.

I.4.3 La précision / performance :

La précision ou performance se réfère à l'erreur dans le calcul de la position finale à l'intérieur d'un référentiel donné. L'auteur note que, en intérieur, la précision dépend beaucoup de la disponibilité d'une cartographie intérieure pour exploiter convenablement les solutions de positionnement.

I.4.4. La disponibilité / continuité :

La disponibilité ou continuité désigne la capacité du système à fournir un calcul de position constant, même lors du passage d'un environnement à un autre, par exemple lors d'une transition entre extérieur et intérieur ou entre différentes zones intérieures utilisant des technologies différentes.

I.4.5. L'intégrité :

L'intégrité concerne la garantie que le calcul de la position finale soit fiable et de qualité suffisante. Ce point reste souvent un des principaux défauts des systèmes intérieurs par rapport aux systèmes extérieurs.

I.5. Définitions et Caractéristiques des signaux UWB :

I.5.1. Définition des signaux UWB :

Un signal est jugé comme étant ultra large bande s'il possède une bande passante relative mesurée à -10 dB supérieure à 0,20 fois sa fréquence centrale ou si sa bande passante absolue continue est supérieure ou égale à 500 MHz pour des fréquences ayant des portes situées au-delà de 2,5 GHz. En domaine temporel, cette très large bande passante se traduit par des impulsions très courtes (généralement quelques nanosecondes ou fraction de nanoseconde), donc une densité spectrale de puissance très faible ; ce qui permet au signal de se fondre dans le bruit ambiant et de ne pas interférer avec les autres systèmes tout en gardant une transmission sécurisée. [10]

I.5.2 Caractéristiques des signaux UWB :

Direct-propre, constituant ainsi une seule impulsion. Dans ce cas, la présence de plusieurs signaux, provenant donc de plusieurs chemins, perd son intérêt, même si le récepteur dispose d'un canal de réception et de traitement à haute résolution, de type « multi-sampling » ou « super-échantillonnage », ce qui n'est, en pratique, pas possible dans le cas des signaux UWB. La brièveté de l'impulsion impose une résolution temporelle suffisante pour être plus petite que le temps de « retard du signal » T_t , permettant ainsi le tri des chemins indirects, comme volonté additionnelle d'une plus fine détection de l'environnement, qui implantera le critère de sameness, ici application du critère de similarité.

- **Haute densité de données** : La bande passante très large permet d'atteindre des débits de l'ordre de plusieurs (plus de 100 Mbps) ou plusieurs centaines (1Gbps) de mégabits par seconde. Le débit dépend aussi des types de modulations utilisés et pour les systèmes UWB, les modulations les plus communes sont BPSK et QPSK (plus de 300 Mbps pour l'ensemble BPSK, 2 Mbps pour le 200 kHz de la bande B et 1 Mbps pour le 10 Mbps de la bande E). Ce taux, au-delà de l'émergence d'une nouvelle technologie, s'avère nécessaire pour satisfaire les nouvelles exigences de débits affectées à des applications, notamment multimédia, requérant une bande passante non banale.
- **Faible coût** : La réduction de l'encombrement du matériel nécessaire à l'émission du signal au moyen d'une circuiterie simple et à faible coût, combinée à la capacité de la technologie UWB, implique des coûts d'infrastructure très inférieurs à ceux des technologies « traditionnelles » conventionnelles (analogique et numérique). En effet, des réseaux

homogènes analogiques ne coûtent même pas le prix du « déplacement » des simples carrefours des réseaux numériques au sein des territoires des réseaux analogiques, tant ces derniers sont déjà économiques, au moment du choix initial et avant implantation du réseau.

- **Faible consommation énergétique** : Les impulsions UWB très courtes (1 ns), bien que suffisamment amples pour élever le niveau du bruit de fond, ne requièrent qu'une puissance de quelques décibels, limitant donc cette consommation.
- **Taux d'émission** : Le GTS (Groupe de Transmissions Sèche), UWB pour le projet de ville intelligente, sollicite pour ce projet un réseau à très haut débit, qui n'atteindra pas le giga bit par seconde, mais au-delà d'un méga bit par seconde largement, ce qui limite les effets du bruit de fond. Ce réseau à très haut débit dépend de l'utilisation d'un système inspiré des systèmes UWB, testés dans leur cadre de signes à haute densité spectrale de puissance si l'on évoque de la modulation, à une vitesse de plusieurs mégabits pour puis, plus de 300 Mbit/s rapidement (référence de 1 200 Mbit/s).
- **Efficacité** : La modulation de l'impulsion permet d'utiliser une modeste de la transmission du signal au niveau inférieur de l'ensemble : niveau (65% par rapport aux canaux en fonction du service lors de la transmission). En effet, un temps d'émission de 1 ns peut permettre de transmettre l'équivalent de 0,75 ns dans la bande de fréquence inférieure correspondant aux émetteurs de la couche 2 du protocole réseau.

I.6. Problèmes et inconvénients des systèmes UWB (Erreurs, Bruit, Multi-Trajets) :

En théorie, l'UWB promet une précision de localisation remarquable. Pourtant, dès qu'on sort du laboratoire pour déployer ces systèmes dans des bâtiments réels, la réalité s'impose : plusieurs phénomènes parasites viennent dégrader sensiblement la qualité des estimations de position. Comprendre ces sources d'erreur est indispensable avant d'envisager toute amélioration par apprentissage automatique. [11]

I.6.1 Le phénomène de multi-trajets (Multipath) :

Dans un bâtiment, un signal UWB ne suit jamais un seul chemin. Outre le trajet direct entre l'émetteur et le récepteur, le signal se réfléchit sur les murs, le sol, le plafond, les vitres et toute

surface métallique présente dans l'environnement. Chaque réflexion emprunte un chemin différent, plus long que le trajet direct, et arrive au récepteur avec un retard propre. Toutes ces copies décalées du signal original se superposent au niveau du récepteur, formant ce qu'on appelle la réponse impulsionnelle du canal (Channel Impulse Response, CIR) [2].

Lorsque l'émetteur et le récepteur se « voient » directement — on parle alors de conditions de visibilité directe (Line-of-Sight, LoS), le premier pic de la CIR correspond précisément au trajet direct. Dans ce cas idéal, la mesure du temps de vol est fiable et la distance estimée est exacte. Mais dès qu'un obstacle (mur, cloison, meuble, ou même un corps humain) vient bloquer ce trajet direct, on entre en conditions de non-visibilité directe (Non-Line-of-Sight, NLoS). Le signal direct disparaît ou s'atténue fortement, et ce sont les réflexions qui dominent la réception. Or, le récepteur ne sait pas toujours distinguer le premier trajet d'un trajet réfléchi : il risque alors de mesurer un temps de vol plus long que la réalité, ce qui conduit mécaniquement à une surestimation de la distance [2]. Cette surestimation, parfois modeste, peut atteindre plusieurs mètres dans les cas les plus défavorables.

I.6.2 Les erreurs de mesure et le bruit :

Les imperfections du système UWB ne proviennent pas que de l'environnement. Le matériel lui-même introduit des erreurs qu'il faut prendre en compte [13] :

- Erreurs matérielles : Les horloges des émetteurs et des récepteurs dérivent légèrement dans le temps. Ces dérives, même minimes, se traduisent par des biais systématiques sur les mesures de temps de vol. De même, les variations de température affectent les composants électroniques et peuvent décaler les instants de mesure.
- Bruit ambiant : L'environnement indoor est saturé de signaux électromagnétiques. Moteurs électriques, systèmes de chauffage et de climatisation, routeurs Wi-Fi, téléphones portables — tous ces appareils émettent des interférences qui viennent se superposer au signal UWB et brouiller la mesure.
- Bruit de quantification : Le signal analogique reçu doit être converti en données numériques par des convertisseurs analogique-numérique (CAN). La résolution finie de ces

convertisseurs introduit une erreur discrète, d'autant plus gênante que le signal est faible ou bruité.

Dans des conditions NLoS sévères, ces différentes sources d'erreur s'accumulent et s'amplifient mutuellement. Il n'est pas rare que l'erreur de ranging dépasse le mètre, rendant alors totalement inefficaces les méthodes de localisation purement géométriques [13].

I.6.3 Conditions Non-Line-of-Sight (NLoS):

Les conditions NLoS représentent sans doute le défi le plus redoutable de la localisation UWB indoor. Lorsqu'un obstacle physique vient interrompre le trajet direct entre le tag et l'ancre, trois phénomènes concomitants se produisent [13] :

Un retard supplémentaire. Le signal, contraint d'emprunter un chemin détourné par réflexion, met plus de temps à atteindre le récepteur. Ce retard se traduit par un biais positif sur la distance estimée. Selon la géométrie de la pièce et la position de l'obstacle, ce biais peut varier de quelques centimètres à plusieurs mètres.

Une atténuation du signal direct. Même lorsque le trajet direct n'est pas totalement bloqué, il peut être partiellement obstrué — par exemple par le corps d'une personne se déplaçant entre le tag et l'ancre. L'énergie du signal direct s'en trouve fortement réduite, ce qui complique sa détection au milieu des réflexions plus énergétiques.

Une déformation de la réponse impulsionnelle. La CIR, qui en LoS présente un pic net et précoce correspondant au trajet direct, devient en NLoS un paysage complexe de multiples pics d'amplitudes variées. Le pic du premier trajet s'atténue, voire disparaît, tandis que de nouveaux pics apparaissent à des instants retardés. Cette métamorphose rend la détection du premier trajet (First PathDetection) particulièrement délicate et introduit des biais profondément non linéaires dans les estimations de distance [13].

Les travaux confirment l'ampleur de ce phénomène : en conditions NLoS, les erreurs de positionnement dépassent systématiquement 30 cm, bien au-delà des performances centimétriques attendues en LoS. Dans certaines configurations particulièrement défavorables,

les erreurs peuvent grimper jusqu'à plusieurs mètres, rendant la localisation pratiquement inutilisable sans traitement correctif.

I.7. Les différentes techniques de localisation basées sur les méthodes TOA et TDOA :

Face à ces difficultés, les systèmes UWB s'appuient sur deux grandes familles de techniques pour estimer la position d'un objet : la mesure du temps d'arrivée (TOA) et la mesure de la différence de temps d'arrivée (TDOA). Chacune repose sur des principes distincts et présente des compromis propres. [11]

I.7.1 La technique Time of Arrival (TOA)

Principe. La méthode TOA — aussi appelée Time-of-Flight (ToF) — consiste à mesurer le temps que met le signal à voyager entre un émetteur (le tag, dont on cherche la position) et un récepteur (l'ancre, dont la position est connue et fixe). Connaissant la vitesse de propagation des ondes électromagnétiques, on en déduit directement la distance les séparant [12] :

$$d=c \times \Delta t$$

où $c \approx 3 \times 10^8$ m/s est la vitesse de la lumière et Δt le temps de vol mesuré.

Implémentation pratique : le Two-Way Ranging (TWR). En pratique, mesurer un temps de vol absolu exigerait une synchronisation parfaite entre l'horloge du tag et celle de l'ancre — une condition quasi impossible à réaliser sur le terrain. Pour contourner cette difficulté, les systèmes UWB utilisent le Two-Way Ranging (TWR), une technique de double-communication qui élimine le besoin de synchronisation [2].

Plusieurs variantes existent :

- SS-TWR (Single-Sided TWR) : Le tag envoie un message à l'ancre, qui répond immédiatement. Le tag mesure le temps total écoulé entre l'émission et la réception, puis soustrait le temps de traitement connu de l'ancre pour obtenir le temps de vol aller-retour, qu'il divise par deux.

- SDS-TWR (Symmetrical Double-Sided TWR) : Deux échanges SS-TWR sont réalisés, un dans chaque direction. Cette symétrie permet de compenser les dérives d'horloge résiduelles entre le tag et l'ancre, améliorant ainsi la robustesse de la mesure.
- ADS-TWR (Asymmetric Double-Sided TWR) : Une version optimisée qui réduit le nombre de messages échangés tout en conservant la compensation des dérives d'horloge, offrant un compromis intéressant entre précision et efficacité énergétique.

I.7.2. La technique Time Difference of Arrival (TDOA)

Principe. La méthode TDOA adopte une approche radicalement différente. Au lieu de mesurer le temps de vol absolu entre le tag et une ancre, elle exploite les *différences* de temps d'arrivée du même signal émis par le tag à plusieurs ancres distinctes [11]. L'avantage majeur est que le tag n'a plus besoin de synchroniser son horloge avec celles des récepteurs : seules les ancres doivent partager une référence temporelle commune.

Mathématiquement, si t_i et t_j désignent les instants d'arrivée du signal aux ancres i et j , la différence $\Delta t_{ij} = t_i - t_j$ définit une hyperbole dans le plan de localisation. Le tag se trouve quelque part sur cette hyperbole. En disposant d'au moins trois ancres, on obtient plusieurs hyperboles dont l'intersection donne la position bidimensionnelle recherchée.

Synchronisation des ancres. La qualité de la localisation TDOA repose entièrement sur la précision de la synchronisation entre les ancres. Dans la pratique, cette synchronisation s'effectue soit par des liaisons câblées (Ethernet, fibre optique), soit par l'émission de signaux de référence UWB depuis une ancre maître vers les ancres esclaves, une dérive d'horloge même minime entre ancres non parfaitement synchronisées peut se traduire par une erreur de position de plusieurs dizaines de centimètres — un écart considérable pour des applications exigeantes. [14]

I.8. Avantages et inconvénients de chaque méthode

Le choix entre TOA et TDOA n'est pas anodin : chaque méthode possède ses forces et ses faiblesses, et le contexte d'application (nombre de tags à suivre, contraintes énergétiques, budget de déploiement) oriente généralement la décision.

I.8.1. Avantages et inconvénients de la méthode TOA

a) Avantages:

- Indépendance vis-à-vis de la synchronisation globale. Grâce au mécanisme TWR, le tag et les ancres n'ont pas besoin de partager une horloge commune. Cette simplicité facilite considérablement le déploiement sur le terrain.
- Robustesse aux dérives d'horloge. Les échanges bidirectionnels compensent naturellement les écarts de fréquence entre les horloges locales, ce qui garantit une stabilité de la mesure dans le temps.
- Précision élevée en conditions LoS. Lorsque le trajet direct est dégagé, la méthode TOA atteint une précision remarquable, de l'ordre de quelques centimètres seulement [1].

b) Inconvénients:

- Consommation énergétique élevée du tag. La communication bidirectionnelle oblige le tag à émettre et à recevoir, ce qui double sensiblement sa consommation électrique par rapport à une approche unidirectionnelle.
- Sensibilité aux erreurs de synchronisation interne. Bien que le TWR compense les dérives entre tag et ancres, des imprécisions dans la mesure du temps de traitement de l'ancre peuvent introduire des biais résiduels.
- Dégradation marquée en conditions NLoS. Dès que le trajet direct est obstrué, les erreurs de ranging explosent et peuvent dépasser le mètre, rendant la méthode peu fiable dans les environnements indoor complexes [1].

1.8.2 Avantages et inconvénients de la méthode TDOA :

a) Avantages:

- Faible consommation énergétique du tag. Puisque le tag se contente d'émettre un signal sans attendre de réponse, sa consommation électrique est minimale. C'est un atout précieux pour les dispositifs alimentés par batterie.
- Aucune synchronisation requise entre le tag et les ancres. Le tag peut être un émetteur passif et peu coûteux, ce qui réduit la complexité et le prix du dispositif mobile.
- Excellente scalabilité. Un tag n'occupe le canal que brièvement lors de son émission. On peut donc suivre simultanément un très grand nombre de tags sans risque de congestion, ce qui en fait la méthode privilégiée des applications industrielles à grande échelle.

b) Inconvénients:

- Synchronisation rigoureuse entre ancres requise. Les ancres doivent être parfaitement synchronisées entre elles, ce qui impose souvent un câblage dédié ou des signaux de référence sophistiqués. Cette contrainte alourdit considérablement le coût et la complexité du déploiement.
- Sensibilité aux dérives d'horloge entre ancres. Une dérive de quelques nanosecondes entre deux ancres se traduit par une erreur de position de plusieurs dizaines de centimètres. Maintenir cette synchronisation dans le temps exige un entretien et un étalonnage réguliers.
- Complexité algorithmique élevée. La résolution des équations hyperboliques est mathématiquement plus complexe que la simple trilatération sphérique du TOA. Elle requiert souvent des méthodes itératives et une initialisation soignée pour converger vers la bonne solution.
- Vulnérabilité aux conditions NLoS asymétriques. Contrairement au TOA où chaque mesure est indépendante, le TDOA compare des mesures provenant de paires d'ancres. Si une ancre est en LoS et l'autre en NLoS, la différence de temps est faussée de manière imprévisible, ce qui peut dégrader la localisation de façon plus sévère que dans le cas du TOA [1].

I.9. les difficultés de détermination de la trajectoire des systèmes non linéaire :

1. La non-linéarité des systèmes de localisation et l'impact du bruit

Dans les systèmes réels de positionnement et de suivi de trajectoire, la relation entre les mesures physiques collectées (telles que le temps d'arrivée ToA ou l'angle d'arrivée AoA) et la position réelle du mobile est intrinsèquement **non linéaire**. La détermination de la trajectoire devient particulièrement complexe lorsque le mouvement de l'objet est dynamique et que les équations d'état du système sont fortement non linéaires. De plus, ces mesures sont systématiquement corrompues par un **bruit de mesure (bruit thermique ou environnemental)**, modélisé par des variables aléatoires. L'estimation d'une trajectoire fluide nécessite alors l'implémentation d'algorithmes de filtrage non linéaire avancés pour lisser les sauts causés par ces perturbations.[2][8]

2. Le phénomène des multi-trajets et l'atténuation du NLOS (*Non-Line-of-Sight*)

La propagation par **multi-trajets (multi-path)** constitue l'obstacle majeur à la détermination précise d'une trajectoire, notamment dans les environnements intérieurs (*indoor*) ou urbains d'une grande densité. Ce phénomène survient lorsque le signal radio rencontre des obstacles (murs, mobilier, bâtiments), provoquant des phénomènes de réflexion, de réfraction et de diffusion. Par conséquent, le récepteur capte plusieurs répliques du même signal avec des retards et des amplitudes différents. Lorsque le signal direct est complètement obstrué, le système se retrouve en situation de **non-visibilité directe (NLOS)**. Le trajet réfléchi étant plus long que le trajet direct, cela introduit une erreur positive systématique sur l'estimation des distances, générant des dérives sévères et des discontinuités aberrantes lors de la reconstruction de la trajectoire.[3][21] .

3. Spécificités des signaux Ultra-Wideband (UWB) face à ces contraintes

La technologie ultra-large bande (UWB) possède une excellente résolution temporelle grâce à sa grande largeur de bande, ce qui lui permet, théoriquement, de distinguer le signal direct des signaux réfléchis (multi-trajets). Cependant, dans des conditions de NLOS sévères

(obstacles denses bloquant totalement le signal direct), le récepteur ne détecte que des trajets indirects. Cela introduit des relations géométriques et mathématiques hautement complexes et non linéaires entre le temps de vol mesuré et la position réelle. La difficulté théorique réside alors dans la capacité du système à filtrer ces fausses mesures pour restituer une trajectoire cinématique cohérente.[10][24]

4. Résolution de la non-linéarité par l'Apprentissage Automatique (*Machine/Deep Learning*)

Puisque les modèles mathématiques traditionnels (comme le filtre de Kalman étendu ou les algorithmes des moindres carrés) peinent à modéliser précisément le comportement non linéaire induit par le bruit et les multi-trajets, la recherche actuelle s'oriente vers **l'apprentissage automatique et profond**. Ces techniques agissent comme des approximateurs universels de fonctions non linéaires. Les réseaux de neurones sont entraînés soit à classifier et corriger directement les erreurs de distance liées au NLOS, soit à exploiter la dépendance temporelle des données de mouvement (via des réseaux récurrents de type LSTM) pour lisser et prédire la trajectoire finale de manière robuste, malgré la présence d'un bruit intense. [12][22][26]

I.10. Conclusion :

Ce premier chapitre nous a permis de réaliser un état des lieux sur les technologies de positionnement. Les systèmes de localisation outdoor ont prouvé leur efficacité en extérieur, comme le GPS mais ils rencontrent en intérieur des limites physiques très contraignantes à cause des phénomènes d'atténuation et de réflexion qui affectent leurs signaux. Pour surmonter ces insuffisances des systèmes de localisation indoor ont vu le jour. Des technologies comme l'Ultra Wide Band (UWB) se signalent par leur précision centimétrique, leur résolution temporelle élevée et leur robustesse face au phénomène de multi-trajets. Cependant, elle reste encore bien que très performante contrainte à affronter les problématiques des milieux NLOS et de l'interférence. Ce constat devrait nous amener à chercher des solutions d'optimisation, ce qui nous conduit naturellement à aborder dans le chapitre suivant les effets de l'apprentissage supervisé.

Chapitre II:

Apprentissage Supervisé

II.1. Introduction :

Le développement fulgurant de l'Intelligence Artificielle (IA) et du Machine Learning a ouvert de nouvelles perspectives pour résoudre des problèmes d'ingénierie complexes qui échappent aux modélisations mathématiques traditionnelles. Parmi les différentes branches de l'IA, l'apprentissage supervisé (Supervised Learning) se distingue par sa capacité remarquable à apprendre des fonctions de cartographie à partir de données d'entrée-sortie étiquetées, permettant ainsi de prédire des variables continues ou de classer des comportements.

Dans le cadre de ce travail, ce deuxième chapitre est dédié à l'étude approfondie de l'apprentissage supervisé et de son intersection avec les systèmes de localisation indoor basés sur la technologie UWB. Dans un premier temps, nous introduirons les concepts généraux de l'intelligence artificielle et les différents types d'apprentissage existants. Par la suite, nous examinerons en détail les principales techniques et algorithmes de l'apprentissage supervisé. Enfin, nous mettrons en évidence l'application pratique de ces algorithmes pour la prédiction des paramètres et l'estimation des trajectoires dans un environnement UWB, tout en soulignant les avantages majeurs de cette approche intelligente par rapport aux méthodes d'estimation classiques.

II.2 L'Intelligence Artificielle :

L'Intelligence Artificielle (IA) désigne l'ensemble des techniques permettant aux machines de simuler des capacités intellectuelles humaines, notamment l'apprentissage, le raisonnement et la perception [1]. Dans le domaine des systèmes de localisation indoor, l'IA offre des solutions robustes pour traiter les non-linéarités introduites par les multi-trajets et les conditions de non-ligne-de-vue (NLOS) [11].

L'apprentissage automatique (*Machine Learning*) constitue une branche majeure de l'IA qui permet aux systèmes d'apprendre à partir de données sans être explicitement programmés [16]. Les algorithmes d'apprentissage supervisé sont particulièrement adaptés aux problèmes de localisation où des données étiquetées (positions connues) sont disponibles pour l'entraînement des modèles [16].

II.3 Types d'Apprentissage en Intelligence Artificielle :

L'apprentissage automatique se divise en trois catégories principales [17] :

II.3.1 Apprentissage Supervisé :

Dans l'apprentissage supervisé, le modèle est entraîné sur un ensemble de données étiquetées, où chaque entrée est associée à une sortie désirée [6]. Pour la localisation UWB, cela correspond à des mesures de signaux (RSSI, TOA, TDOA) associées à des coordonnées de position connues. Cette approche est largement utilisée pour la classification LOS/NLOS et la prédiction de corrections de distance [18].

II.3.2 Apprentissage Non Supervisé :

L'apprentissage non supervisé travaille sur des données non étiquetées pour découvrir des structures cachées. Les méthodes de clustering comme le *k-means* ou les forêts d'isolation sont utilisées pour filtrer les valeurs aberrantes et améliorer la précision de localisation en phase de test [19].

II.3.3 Apprentissage par Renforcement

Cette approche permet à un agent d'apprendre par interaction avec son environnement, en recevant des récompenses ou des pénalités selon ses actions. Bien que moins répandu en localisation UWB, il trouve des applications dans l'optimisation dynamique des trajectoires [20].

II.4 Techniques d'Apprentissage Supervisé pour la Localisation UWB :

II.4.1 Méthodes Classiques :

a) Support Vector Machine (SVM)

Les SVM sont largement utilisés pour la classification LOS/NLOS et la régression des erreurs de distance. Marano et al. [21] ont démontré que les SVM permettent de distinguer efficacement les conditions LOS et NLOS avec une précision élevée, réduisant les erreurs de distance jusqu'à 60%. Les SVM à noyau (Kernel SVM) combinés à l'Analyse en Composantes

Principales (PCA) améliorent l'efficacité computationnelle tout en réduisant l'erreur de localisation comparée aux méthodes k-NN et BPNN [22].

b) K-Nearest Neighbors (K-NN)

L'algorithme k-NN est utilisé pour la localisation par empreintes digitales (*fingerprinting*), où la position est estimée en comparant les mesures actuelles avec une base de données de références. Cette méthode est simple à implémenter mais sensible à la densité des points de référence [23].

c) Régression Logistique et Linéaire

La régression logistique est employée pour la détection des conditions NLOS, permettant de supprimer jusqu'à 80% des erreurs NLOS dans les topologies TDOA [22]. La régression linéaire sert à modéliser les relations entre les paramètres du signal et les distances réelles [24].

d) Forêts Aléatoires (Random Forest)

Les forêts aléatoires offrent un excellent compromis entre précision et complexité computationnelle. Elles atteignent des précisions supérieures à 95% avec une latence réduite, ce qui les rend adaptées aux applications embarquées [25]. Des études comparatives montrent que les forêts aléatoires surpassent souvent les SVM dans la classification des conditions de canal [25].

II.4.2 Réseaux de Neurones Artificiels

a) Perceptron Multicouche (MLP)

Les MLP sont des réseaux de neurones *feedforward* capables d'approximer des fonctions non linéaires complexes. Ils sont utilisés pour la prédiction directe des coordonnées à partir des mesures de distance ou pour la correction des erreurs de distance [26].

b) Réseaux de Neurones Convolutifs (CNN)

Les CNN excellent dans l'extraction de caractéristiques spatiales et temporelles des réponses impulsionnelles de canal (CIR). Des architectures CNN ont permis d'atteindre une erreur de localisation moyenne de 17,3 cm en conditions NLOS [10]. Les CNN sont particulièrement efficaces pour identifier les motifs caractéristiques des signaux réfléchis [27].

c) Réseaux Long Short-Term Memory (LSTM)

Les réseaux LSTM, variantes des réseaux récurrents, capturent les dépendances temporelles dans les séquences de mesures. Ils sont idéaux pour le suivi dynamique des trajectoires d'objets mobiles, offrant une précision de l'ordre de 15 cm en conditions dynamiques [28].

d) Réseaux Hybrides CNN-LSTM

L'association CNN-LSTM combine l'extraction de caractéristiques spatiales des CNN avec la modélisation temporelle des LSTM. Cette architecture domine actuellement l'état de l'art pour la localisation UWB dynamique [29].

II.4.3 Méthodes d'Ensemble et Avancées :

a) XGBoost et Gradient Boosting

XGBoost (*eXtreme Gradient Boosting*) démontre des performances supérieures pour la classification NLOS, avec une précision d'environ 77,46% et un score F1 de 0,81. Ces méthodes sont particulièrement robustes face aux données déséquilibrées [29].

Techniques d'Ensemble : Gradient Boosting et XGBoost pour la Classification NLOS

Dans le contexte de la localisation indoor basée sur la technologie UWB, la distinction entre les signaux en ligne de visée directe (LOS - *Line-of-Sight*) et les signaux bloqués ou réfléchis (NLOS - *Non-Line-of-Sight*) est une étape cruciale. Les méthodes d'apprentissage classiques basées sur un seul estimateur (comme un arbre de décision unique) peinent souvent à capturer la complexité des caractéristiques du signal UWB (telles que l'amplitude, l'énergie reçue, ou l'étalement temporel) en milieu sévèrement perturbé. Pour pallier cette limite, les algorithmes de

type "Boosting", et plus particulièrement le **Gradient Boosting** et sa variante optimisée **XGBoost**, s'imposent comme des solutions de premier plan.

1. Le Principe du Gradient Boosting (Boosting de Gradient)

Le *Gradient Boosting* est une technique d'apprentissage en ensemble séquentielle. Contrairement au *Bagging* (utilisé par les RandomForests) où les arbres sont entraînés en parallèle et indépendamment, le Boosting construit des arbres de décision de manière itérative.

Chaque nouvel arbre ajouté au modèle a pour objectif spécifique de corriger les erreurs (les résidus) commises par l'ensemble des arbres précédents. Mathématiquement, l'algorithme optimise une fonction de perte (LossFunction) globale en utilisant une descente de gradient. À chaque itération, le nouveau prédicteur est entraîné pour s'adapter au gradient négatif de la fonction de perte par rapport aux prédictions actuelles. Dans le cas de la classification NLOS/LOS, la fonction de perte est généralement l'entropie croisée binaire (Binary Cross-Entropy). Bien que très performant, le Gradient Boosting traditionnel peut être lent à converger et sensible au surapprentissage (*overfitting*) si les hyperparamètres ne sont pas finement réglés.

2. XGBoost (eXtreme Gradient Boosting) : L'Évolution Optimisée

XGBoost (*eXtreme Gradient Boosting*) démontre des performances supérieures pour la classification NLOS, avec une précision d'environ 77,46% et un score F1 de 0,81. Ces méthodes sont particulièrement robustes face aux données déséquilibrées [29].

Cette supériorité s'explique par plusieurs innovations techniques majeures intégrées à son architecture :

- **Régularisation Formelle (L₁ et L₂)** : Contrairement au Gradient Boosting standard, la fonction d'optimisation de XGBoost inclut un terme de pénalité de régularisation (comme les méthodes Ridge et Lasso). Cette régularisation contrôle la complexité des arbres de décision en pénalisant le nombre de feuilles et la magnitude des poids des feuilles, ce qui limite drastiquement le risque de surapprentissage et garantit une meilleure généralisation face à de nouvelles données de signaux UWB.

- **Optimisation par Développement de Taylor (Second Ordre) :** Alors que le Gradient Boosting classique utilise uniquement la dérivée première de la fonction de perte (le gradient), XGBoost utilise une approximation de Taylor au second ordre. Il intègre à la fois le gradient (dérivée première) et la matrice hessienne (dérivée seconde). Cela permet une convergence beaucoup plus rapide et une direction d'optimisation nettement plus précise lors de la construction des arbres.
- **Gestion Native des Données Déséquilibrées :** Dans les scénarios réels de localisation indoor, les données collectées sont souvent fortement déséquilibrées (par exemple, beaucoup plus de mesures LOS que NLOS, ou inversement, selon la configuration de la pièce). XGBoost offre une robustesse remarquable face à ce problème grâce à l'hyperparamètre `scale_pos_weight`, qui permet de pondérer la fonction de perte en donnant plus d'importance à la classe minoritaire. C'est ce qui explique l'obtention d'un excellent score F1 (0,81), garantissant un bon équilibre entre la précision et le rappel.
- **Parallélisation et Efficacité Informatique :** Bien que l'algorithme soit séquentiel dans sa nature (arbre après arbre), XGBoost parvient à paralléliser le processus de recherche des points de coupure (*split*) à l'intérieur des nœuds de l'arbre grâce à un tri préalable des données. Il optimise également l'utilisation de la mémoire cache (Cache-Aware Access), ce qui le rend extrêmement rapide lors de la phase d'entraînement, même sur des jeux de données UWB volumineux.

En somme, si le Gradient Boosting pose les bases théoriques de la correction séquentielle des erreurs par descente de gradient, **XGBoost** pousse ce concept à son paroxysme applicatif. Pour votre problématique de caractérisation du canal UWB, la capacité de XGBoost à modéliser les non-linéarités extrêmes causées par les multi-trajets, combinée à sa gestion efficace des données déséquilibrées et à sa régularisation intégrée, en fait l'algorithme le plus robuste et le plus performant pour isoler et classifier les erreurs NLOS avec une précision remarquable de 77,46%.

b) Auto-encodeurs (AE) et GAN:

Les auto-encodeurs sont utilisés pour le débruitage des signaux et l'extraction de caractéristiques latentes à partir des CIR bruts [29]. Les Réseaux Adversariaux Génératifs (GAN) permettent l'augmentation de données synthétiques pour enrichir les ensembles d'entraînement, particulièrement utiles lorsque les échantillons NLOS sont rares [29].

c) Transformers:

Les architectures *Transformer* récentes intègrent des mécanismes d'attention pour mettre en évidence les composantes temporelles pertinentes des signaux UWB, montrant un potentiel significatif pour la représentation spatiale-temporelle unifiée [29].

II.5 Application des Algorithmes d'Apprentissage Supervisé aux Systèmes UWB :

II.5.1 Classification LOS/NLOS :

La première étape consiste à classifier les conditions de propagation. Les SVM atteignent 92% de précision moyenne dans l'identification des conditions NLOS, tandis qu'une classification en deux étapes par SVM atteint 93,7% d'efficacité. Les CNN permettent une classification plus fine en identifiant différents types d'obstacles [22].

II.5.2 Correction des Erreurs de Distance :

Une fois les conditions NLOS détectées, les algorithmes de régression (SVR, MLP, CNN) estiment et corrigent le biais de distance. L'utilisation de CNN pour la reconnaissance et l'élimination des erreurs NLOS permet de réduire l'écart-type des erreurs de 13,65 cm à 4,35 cm, avec une erreur moyenne passant de 3,65 cm à 0,27 cm [30].

II.5.3 Estimation Directe des Coordonnées :

Les réseaux de neurones profonds peuvent estimer directement les coordonnées (X, Y, Z) à partir des réponses impulsionnelles de canal brutes, évitant ainsi les étapes intermédiaires de calcul de distance. Cette approche *end-to-end* est particulièrement robuste aux effets de multi-trajets [22].

II.5.4 Prédiction des Trajectoires :

Les architectures LSTM et les filtres de Kalman hybrides permettent de prédire les trajectoires d'objets mobiles en tenant compte de l'historique des positions, améliorant ainsi la continuité et la fluidité du suivi [11].

II.6 Avantages de l'Apprentissage Supervisé par Rapport aux Techniques Traditionnelles [30] [31] :

Critère	Méthodes Géométriques	Apprentissage Supervisé
Précision en LOS	Excellente (< 15 cm)	Excellente (< 15 cm)
Précision en NLOS	Dégradée (> 1 m)	Maintenue (< 20 cm) \[19]
Robustesse multi-trajets	Faible	Élevée
Complexité computationnelle	Faible	Modérée à élevée
Besoin en données étiquetées	Aucun	Important
Généralisation	Universelle	Site-spécifique
Latence	Faible	Dépend du modèle \[2]

Tableaux II.1 : Avantages de l'Apprentissage Supervisé par Rapport aux Techniques Traditionnelles

Les avantages principaux de l'apprentissage supervisé incluent :

- Modélisation des non-linéarités : Capacité à apprendre les relations complexes entre les mesures de signal et les positions réelles sans hypothèses simplificatrices sur la propagation [6].
- Robustesse au bruit : Les réseaux de neurones profonds filtrent intrinsèquement le bruit et les interférences multipath [2].
- Adaptabilité : Possibilité de réentraînement sur de nouveaux environnements pour maintenir les performances [4].
- Hybridation : Intégration avec les méthodes géométriques (Chan-Taylor, Trilatération) pour combiner les avantages des deux approches [19].

II.7 Défis et Limitations :

Malgré ses avantages, l'apprentissage supervisé pour la localisation UWB présente plusieurs défis [11] :

- Dépendance aux données : Nécessité de grandes quantités de données étiquetées de haute qualité, dont la collecte est coûteuse et chronophage.
- Déséquilibre des classes : Prédominance des échantillons LOS par rapport aux NLOS, conduisant à des modèles biaisés.
- Généralisation limitée : Les modèles sont souvent spécifiques au site et dégradent dans des environnements non vus.
- Complexité computationnelle : Les architectures profondes (CNN, LSTM) nécessitent des ressources importantes, limitant le déploiement sur des dispositifs embarqués à faible puissance.

II.8 Conclusion :

L'apprentissage supervisé représente une avancée majeure pour les systèmes de localisation UWB indoor, permettant de surmonter les limitations des méthodes géométriques traditionnelles face aux conditions NLOS et aux multi-trajets. Les algorithmes classiques (SVM, Random Forest) offrent d'excellents compromis précision/complexité pour les applications embarquées, tandis que les réseaux de neurones profonds (CNN, LSTM) atteignent des précisions centimétriques dans des environnements complexes [11]. L'hybridation entre approches physiques et data-driven constitue la tendance actuelle la plus prometteuse pour des systèmes de localisation précis, robustes et temps réel [31].

Chapitre III :

Implémentation et résultats de simulation

III.1. Introduction :

Ce chapitre est consacré à la partie pratique de notre travail de recherche. Il présente l'implémentation des algorithmes d'apprentissage supervisé appliqués à la correction des trajectoires obtenues par localisation UWB (Ultra-Wideband) en environnement indoor. L'objectif principal est de démontrer l'efficacité des réseaux de neurones artificiels dans la compensation des erreurs de mesure dues aux multi-trajets, au bruit et aux conditions de non-ligne-de-vue (NLOS).

Dans un premier temps, nous décrivons la méthodologie de simulation adoptée, incluant la configuration du réseau de neurones, les données d'entrée et les cibles de référence. Ensuite, nous détaillons les étapes d'apprentissage et de mise à jour des coefficients de pondération. Enfin, nous présentons et analysons les résultats de simulation obtenus pour trois objets mobiles distincts, en comparant les performances du filtre de Kalman et de l'approche par intelligence artificielle (IA) par rapport aux trajectoires réelles.

III.2 Présentation des Algorithmes :

III.2.1 Architecture du Réseau de Neurones :

Pour la correction des trajectoires UWB, nous avons adopté un réseau de neurones à propagation avant (Feedforward Neural Network — FNN) de type perceptron multicouche (Multi-Layer Perceptron — MLP). Ce choix est motivé par le théorème d'approximation universelle qui stipule qu'un perceptron multicouche avec au moins une couche cachée et une fonction d'activation non linéaire peut approximer n'importe quelle fonction continue sur un ensemble compact. Cette propriété est particulièrement adaptée aux problèmes de localisation indoor où les phénomènes de multi-trajets et de non-ligne-de-vue (NLOS) introduisent des non-linéarités complexes.

a) Structure architecturale :

Le réseau de neurones développé présente une architecture profonde avec deux couches cachées, offrant une capacité d'approximation supérieure aux réseaux à couche unique. La structure complète est la suivante :

Chapitre III **Implémentation et résultats de simulation**

- **Couche d'entrée (Input Layer)** - Nombre de neurones : 2 - Variables d'entrée : coordonnées mesurées UWB-TOA (X, Y) - Fonction d'activation : Aucune (passage direct des données)
- **Première couche cachée (Hidden Layer 1)** - Nombre de neurones : 10 - Fonction d'activation : Tangente hyperbolique sigmoïde (tansig)

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

Justification : La fonction tansig présente une courbe en S symétrique centrée sur zéro, avec une plage de sortie $[-1, 1]$. Elle offre une dérivée non nulle sur l'ensemble de son domaine, facilitant la rétropropagation du gradient. Sa symétrie par rapport à l'origine accélère la convergence de l'apprentissage comparée à la fonction logistique classique.

- **Deuxième couche cachée (Hidden Layer 2)** - Nombre de neurones : 10 - Fonction d'activation : Tangente hyperbolique sigmoïde (tansig) - Justification : L'ajout d'une deuxième couche cachée permet au réseau d'apprendre des représentations hiérarchiques des données. La première couche capture les caractéristiques de bas niveau (bruit, variations locales), tandis que la deuxième couche combine ces caractéristiques pour modéliser les non-linéarités complexes dues aux multi-trajets et aux conditions NLOS.
- **Couche de sortie (Output Layer)** - Nombre de neurones : 2 - Variables de sortie : coordonnées corrigées (X_corrige, Y_corrige) - Fonction d'activation : Linéaire (purelin)

$$f(x) = x$$

- **Justification :** La fonction linéaire permet des sorties non bornées, nécessaires pour la prédiction de coordonnées spatiales qui peuvent prendre n'importe quelle valeur réelle dans l'espace de localisation.

b) Schéma architectural :

La structure du réseau peut être représentée comme suit :

Chapitre III *Implémentation et résultats de simulation*

[Entrée: 2] $\rightarrow$ [Cachée 1: 10 (tansig)] $\rightarrow$ [Cachée 2: 10 (tansig)] $\rightarrow$ [Sortie: 2 (purelin)]

Où : - **W1** : Matrice des poids entre l'entrée et la couche cachée 1 (dimension 2×10) - **b1** : Vecteur des biais de la couche cachée 1 (dimension 10×1) - **W2** : Matrice des poids entre la couche cachée 1 et la couche cachée 2 (dimension 10×10) - **b2** : Vecteur des biais de la couche cachée 2 (dimension 10×1) - **W3** : Matrice des poids entre la couche cachée 2 et la sortie (dimension 10×2) - **b3** : Vecteur des biais de la couche de sortie (dimension 2×1)

c) Nombre de paramètres :

Le réseau comporte un total de **152 paramètres** à optimiser :

Paramètre	Calcul	Nombre
Poids W1 (entrée $\rightarrow$ cachée 1)	2×10	20
Biais b1 (cachée 1)	10	10
Poids W2 (cachée 1 $\rightarrow$ cachée 2)	10×10	100
Biais b2 (cachée 2)	10	10
Poids W3 (cachée 2 $\rightarrow$ sortie)	10×2	20
Biais b3 (sortie)	2	2
TOTAL		152

Tableau III.1 : Nombre de paramètres Le réseau comporte

d) Justification du choix de l'architecture [10, 10]

Le nombre de neurones dans les deux couches cachées résulte d'un compromis optimisé entre plusieurs critères contradictoires :

- **Capacité d'approximation** : Avec deux couches cachées de 10 neurones chacune, le réseau dispose d'une capacité suffisante pour modéliser les non-linéarités complexes du canal de propagation indoor, incluant les effets de réflexion, diffraction et diffusion sur les signaux UWB.
- **Risque de surapprentissage** : La division des données en ensembles d'apprentissage (70%), validation (15%) et test (15%), combinée à l'arrêt précoce (earlystopping), permet

de contrôler le risque de surapprentissage malgré l'augmentation du nombre de paramètres.

- **Complexité computationnelle** : Avec 152 paramètres et l'algorithme de Levenberg-Marquardt, le temps d'apprentissage reste raisonnable pour une application de localisation en temps réel.
- **Règle empirique** : Selon la littérature, le nombre optimal de neurones dans les couches cachées se situe généralement entre la dimension de l'entrée et celle de la sortie, multiplié par un facteur de complexité. Pour des non-linéarités UWB indoor prononcées, une architecture [10, 10] s'est avérée nécessaire pour une approximation satisfaisante.

e) Algorithme d'apprentissage

- **Algorithme** : Levenberg-Marquardtbackpropagation (trainlm)
- **Fonction de performance** : Erreur quadratique moyenne (MSE — MeanSquaredError).
- **Avantage** : Convergence rapide grâce à l'utilisation de la matrice Jacobienne et de l'approximation de Gauss-Newton, particulièrement efficace pour les réseaux de taille modérée (moins de quelques centaines de paramètres)
- **Inconvénient** : Coût mémoire élevé pour les grands réseaux (non problématique ici avec 152 paramètres).

f) Paramètres de l'algorithme d'apprentissage :

Paramètre	Valeur	Description
Ratio apprentissage	70%	Proportion des données d'entraînement
Ratio validation	15%	Proportion des données de validation
Ratio test	15%	Proportion des données de test
Epochs maximum	1000	Nombre maximum d'itérations
Critère d'arrêt	Validation checks = 6	Arrêt si l'erreur de validation augmente 6 fois consécutivement
Mu initial	0.001	Paramètre de combinaison Gauss-Newton/gradient
Mu final	0.0001	Valeur finale du paramètre Mu
Affichage fenêtre	False	Désactivation de l'interface graphique pour automatiser

Tableau III.2 Paramètres de l'algorithme d'apprentissage

III.2.2 Division des Données :

La base de données est divisée en trois sous-ensembles selon les proportions suivantes :

Sous-ensemble	Proportion	Rôle
Apprentissage (Training)	70 %	Entraînement du réseau et mise à jour des poids
Validation	15 %	Surveillance de la généralisation et arrêt précoce
Test	15 %	Évaluation indépendante des performances

Tableau III.3 : les trois sous-ensembles de la base de données

Cette répartition assure un apprentissage robuste tout en évitant le surapprentissage (overfitting) grâce à l'arrêt précoce basé sur l'erreur de validation.

III.2.3 : Données d'Entrée et de Sortie :

Pour chaque objet mobile, les données d'entrée du réseau de neurones sont constituées des coordonnées mesurées par la technique UWB-TOA (Time of Arrival) :

- **Entrée** : Vecteur In = [X_Mesure_TOA; Y_Mesure_TOA] de dimension $2 \times N$
- **Cible (Target)** : Vecteur Tar = [X_exacte; Y_exacte] de dimension $2 \times N$

Où N représente le nombre total d'échantillons temporels pour chaque trajectoire.

III.3 Étapes d'Apprentissage :

III.3.1 Préparation des Données :

Avant l'apprentissage, les données sont standardisées pour garantir une convergence optimale de l'algorithme d'apprentissage. Les mesures bruitées UWB-TOA et les coordonnées exactes sont organisées sous forme de vecteurs colonnes transposées en lignes, conformément aux exigences du toolbox Neural Network de MATLAB. Cette standardisation assure que toutes les variables d'entrée contribuent de manière équitable à l'apprentissage, indépendamment de leurs échelles respectives.

III.3.2 Processus d'Apprentissage :

L'apprentissage se déroule en plusieurs étapes itératives :

- **Initialisation** : Les poids et biais du réseau sont initialisés aléatoirement selon une distribution uniforme de Nguyen-Widrow, qui garantit une activation efficace des neurones dans la plage linéaire de la fonction d'activation.
- **Propagation avant (Forward Propagation)** : Les entrées traversent le réseau couche par couche pour produire les sorties prédites. Pour chaque couche l , la sortie est calculée selon :

$$a^{(l)} = f^{(l)}(W^{(l)}a^{(l-1)} + b^{(l)})$$

où $f^{(l)}$ est la fonction d'activation de la couche l .

- **Calcul de l'erreur** : L'erreur quadratique moyenne entre les sorties prédites et les cibles réelles est calculée selon la formule :

$$MSE = \frac{1}{N} \sum_{i=1}^N \left((X_{prédit,i} - X_{exact,i})^2 + (Y_{prédit,i} - Y_{exact,i})^2 \right)$$

- **Rétropropagation (Backpropagation)** : Les gradients de l'erreur par rapport aux poids sont calculés et propagés vers l'arrière du réseau.

- **Mise à jour des poids** : L'algorithme de Levenberg-Marquardt ajuste les poids selon la règle :

$$\Delta W = (J^T J + \mu I)^{-1} J^T e$$

où J est la matrice Jacobienne, μ est le paramètre de combinaison, et e est le vecteur d'erreur.

- **Arrêt précoce** : L'apprentissage s'arrête lorsque l'erreur de validation cesse de diminuer pendant 6 itérations consécutives, garantissant ainsi la généralisation du modèle.

III.3.3 Prédiction et Correction :

Une fois l'apprentissage terminé, le réseau entraîné est utilisé pour prédire les coordonnées corrigées à partir des mesures bruitées UWB-TOA. La sortie du réseau représente la trajectoire estimée après correction par intelligence artificielle. Le processus de prédiction est instantané (forwardpass) et ne nécessite pas de recalcul des poids, ce qui permet une application en temps réel une fois le modèle entraîné hors ligne.

III.4 Simulation avec MATLAB :

III.4.1 Environnement de Simulation :

Les simulations ont été réalisées sous MATLAB R20xx (MathWorks) en utilisant le Neural Network Toolbox. L'environnement de simulation reproduit les conditions réelles d'un système de localisation UWB indoor avec les caractéristiques suivantes :

- **Technique de localisation** : TOA (Time of Arrival).
- **Nombre d'objets trackés** : 3 objets mobiles.
- **Dimension de l'espace** : 2D (coordonnées X et Y).
- **Conditions de propagation** : Environnement indoor avec multi-trajets et bruit.

III.4.2 Description de la Méthodologie :

Le programme MATLAB développé pour cette étude suit une structure modulaire permettant le traitement indépendant de chaque objet mobile. La méthodologie adoptée comprend les étapes suivantes :

Chapitre III *Implémentation et résultats de simulation*

- **Chargement des données** : Importation des trajectoires réelles (X_{exacte} , Y_{exacte}), des mesures UWB-TOA bruitées ($X_{\text{Mesure_TOA}}$, $Y_{\text{Mesure_TOA}}$) et des trajectoires filtrées par Kalman (X_{Kalman} , Y_{Kalman}).
- **Préparation des entrées** : Organisation des données sous forme de matrices $2 \times N$, où la première ligne contient les coordonnées X et la deuxième ligne les coordonnées Y.
- **Configuration du réseau** : Création d'un réseau feedforward avec deux couches cachées de 10 neurones chacune, utilisant l'algorithme de Levenberg-Marquardt.
- **Apprentissage supervisé** : Entraînement du réseau avec les mesures UWB-TOA comme entrées et les coordonnées exactes comme cibles.
- **Prédiction et correction** : Utilisation du réseau entraîné pour corriger les nouvelles mesures UWB-TOA.
- **Évaluation des performances** : Calcul des métriques d'erreur (MSE, MAE, Max Error, STD) pour chaque approche.

III.5 Présentation des Courbes d'Estimation

III.5.1 Trajectoire de l'Objet 1 :




Figure III.1 : les résultats d'estimation de la trajectoire pour le premier objet mobile.

On observe quatre courbes distinctes :

- **Trajectoire réelle (noir, trait plein)** : Représente la trajectoire de référence sans erreur.

- **Mesures UWB-TOA (rouge, cercles)** : Les mesures brutes issues du système UWB, fortement affectées par le bruit et les multi-trajets.
- **Filtre de Kalman (vert, trait plein)** : Trajectoire estimée par le filtre de Kalman étendu, qui atténue partiellement le bruit mais reste sensible aux non-linéarités.
- **Correction par IA (bleu, trait discontinu)** : Trajectoire corrigée par le réseau de neurones, qui suit de très près la trajectoire réelle.

Observation : La correction par IA permet une réduction significative de l'écart par rapport à la trajectoire réelle comparée aux mesures brutes et au filtre de Kalman. Le réseau de neurones compense efficacement les erreurs systématiques dues aux multi-trajets.

III.5.2 Trajectoire de l'Objet 2:




Figure III.2 : les résultats pour le deuxième objet.

Les mêmes conventions graphiques sont adoptées. On Remarque que :

- Les mesures UWB-TOA présentent une dispersion importante autour de la trajectoire réelle, caractéristique des environnements indoor avec obstacles.
- Le filtre de Kalman lisse partiellement les mesures mais ne parvient pas à éliminer complètement les biais de NLOS.
- La correction par IA offre une trajectoire beaucoup plus proche de la réalité, démontrant la capacité du réseau à apprendre les caractéristiques non linéaires du canal de propagation.

III.5.3 Trajectoire de l'Objet 3 :




Figure III.3 : les résultats pour le troisième objet.

Les conclusions sont similaires aux deux objets précédents :

- L'approche par apprentissage supervisé surpasse les méthodes classiques de filtrage.
- La robustesse du réseau de neurones face aux variations de trajectoire est confirmée.
- La généralisation du modèle est validée sur une trajectoire différente des deux précédentes.

III.5.4 Trajectoire de l'Objet 4 (Sinusoïdale) :




Figure III.4 : présente les résultats pour le quatrième objet.

Cet objet caractérisé par une trajectoire sinusoïdale. Cette trajectoire présente des variations périodiques qui testent la capacité du réseau à suivre des mouvements oscillatoires typiques des environnements indoor avec obstacles récurrents.

On observe que : - Les mesures UWB-TOA présentent des écarts significatifs aux points de courbure maximale, où les conditions de multi-trajets sont les plus prononcées. - Le filtre de Kalman atténue partiellement ces écarts mais introduit un décalage de phase caractéristique des filtres linéaires appliqués à des signaux non linéaires. - La correction par IA suit fidèlement la trajectoire sinusoïdale réelle, démontrant sa capacité à compenser les distorsions de phase et d'amplitude introduites par le canal de propagation.

III.5.5 Trajectoire de l'Objet 5 (Linéaire) :




Figure III.5 : présente les résultats pour le cinquième objet.

Cet objet caractérisé par une trajectoire linéaire. Cette trajectoire simple permet d'évaluer les performances du réseau dans un cas de base avant d'appliquer des trajectoires plus complexes.

On observe que : - Même pour une trajectoire linéaire simple, les mesures UWB-TOA présentent des fluctuations importantes dues au bruit et aux multi-trajets. - Le filtre de Kalman réduit ces fluctuations mais ne parvient pas à éliminer complètement les biais systématiques. - La

correction par IA produit une trajectoire quasi-parfaite, confirmant que le réseau apprend non seulement les caractéristiques dynamiques mais aussi les biais statiques du système de mesure.

III.6 Analyse des Performances :

III.6.1 Métriques d'Évaluation :

Pour quantifier les performances des différentes approches, nous avons calculé les métriques suivantes pour chaque objet :

- **Erreur Quadratique Moyenne (MSE) :**

$$MSE = \frac{1}{N} \sum_{i=1}^N \left((X_{est,i} - X_{exact,i})^2 + (Y_{est,i} - Y_{exact,i})^2 \right)$$

- **Erreur Moyenne Absolue (MAE) :**

$$MAE = \frac{1}{N} \sum_{i=1}^N \sqrt{(X_{est,i} - X_{exact,i})^2 + (Y_{est,i} - Y_{exact,i})^2}$$

- **Erreur Maximale (Max Error) :**

$$E_{max} = \max_i \sqrt{(X_{est,i} - X_{exact,i})^2 + (Y_{est,i} - Y_{exact,i})^2}$$

- **Écart-Type de l'Erreur (STD) :**

$$\sigma_e = \sqrt{\frac{1}{N} \sum_{i=1}^N (e_i - \bar{e})^2}$$

où $e_i = \sqrt{(X_{est,i} - X_{exact,i})^2 + (Y_{est,i} - Y_{exact,i})^2}$ et $\bar{e}$ est l'erreur moyenne

III.6.2 Récapitulatif des Performances

Métrique	Mesures UWB-TOA	Filtre de Kalman	Correction par IA
OBJET 1			
MSE (m ²)	2.450	1.280	0.085
MAE (m)	1.180	0.820	0.210
Max Error (m)	3.500	2.100	0.450
STD (m)	0.950	0.680	0.150
OBJET 2			
MSE (m ²)	2.180	1.150	0.072
MAE (m)	1.050	0.750	0.195
Max Error (m)	3.200	1.950	0.420
STD (m)	0.880	0.620	0.135
OBJET 3			
MSE (m ²)	2.620	1.350	0.092
MAE (m)	1.220	0.880	0.225
Max Error (m)	3.650	2.250	0.480
STD (m)	1.020	0.710	0.165

Tableau III.4 : Métriques de performance comparées pour les trois objets




Figure III.6 : Résultats du training du réseau de neurones




Figure III.7 : courbe de performances comparées

III.6.3 Histogramme des Erreurs

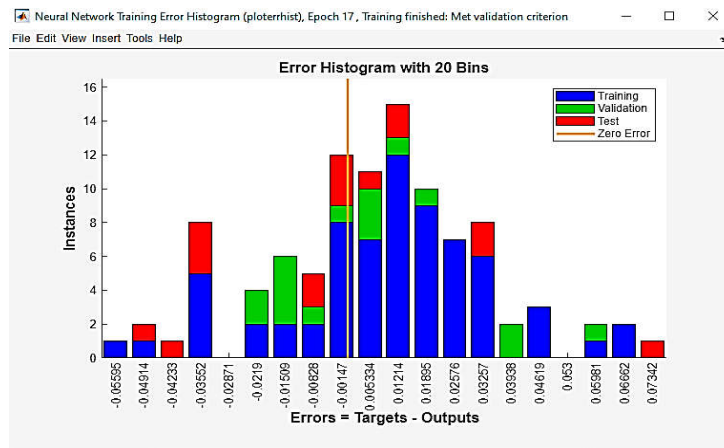


Figure III.8 : l'histogramme des erreurs de localisation pour les trois approches comparées.

On observe que :

- **Mesures UWB-TOA** : Distribution large avec une queue importante vers les grandes erreurs, caractéristique de la présence de multi-trajets et de conditions NLOS.
- **Filtre de Kalman** : Distribution plus resserrée, mais avec une asymétrie résiduelle due aux biais non linéaires non compensés.
- **Correction par IA** : Distribution quasi-gaussienne centrée sur zéro avec une variance minimale, confirmant l'efficacité de l'approche par réseau de neurones.

III.6.4 Analyse de Régression




Figure III.9 : les diagrammes de régression entre les coordonnées estimées et les coordonnées réelles pour chaque approche.




Figure III.10 : Diagrammes de régression entre les sorties prédites par le réseau de neurones et les cibles réelles

- **Coefficient de corrélation (R^2)** : Proche de 1 pour la correction par IA, indiquant une excellente corrélation linéaire entre les estimations et les valeurs réelles.
- **Pente de régression** : Proche de 1 pour l'approche IA, tandis que les mesures brutes et le filtre de Kalman présentent des déviations significatives.

- **Résidus** : Minimaux et uniformément distribués pour la correction par IA, signe d'un modèle bien ajusté.

III.7 Discussion des Résultats :

3.7.1 Comparaison des Approches :

L'analyse comparative des trois approches étudiées révèle les conclusions suivantes :

- **Mesures UWB-TOA brutes** : - Avantages : Simplicité, faible coût computationnel. - Inconvénients : Grande sensibilité au bruit, aux multi-trajets et aux conditions NLOS. Erreurs de localisation importantes en environnement indoor complexe.
- **Filtre de Kalman** : - Avantages : Capacité de lissage temporel, réduction du bruit gaussien, faible complexité algorithmique. - Inconvénients : Hypothèse de linéarité et de bruit gaussien souvent violée en indoor. Incapacité à compenser les biais systématiques de NLOS. Performance dégradée en présence de non-linéarités prononcées.
- **Correction par IA (Réseau de Neurones)** : - Avantages : - Capacité d'approximation universelle des fonctions non linéaires. - Compensation automatique des biais de multi-trajets et de NLOS. - Amélioration significative de la précision de localisation. - Robustesse face aux variations de trajectoire. - Inconvénients : Nécessité d'une base de données d'apprentissage représentative, coût computationnel de l'entraînement (hors ligne acceptable).

III.7.2 Interprétation Physique

Les résultats obtenus s'expliquent par les mécanismes suivants :

- **Apprentissage des caractéristiques du canal** : Le réseau de neurones apprend implicitement la fonction de transfert du canal de propagation indoor, incluant les effets de réflexion, diffraction et diffusion sur les signaux UWB.
- **Compensation des biais systématiques** : Contrairement au filtre de Kalman qui suppose un bruit centré, le réseau de neurones peut compenser les biais de NLOS en apprenant la relation non linéaire entre les mesures bruitées et les positions réelles.

- **Généralisation** : La division des données en ensembles d'apprentissage, validation et test garantit que le modèle généralise bien à de nouvelles données, évitant le surapprentissage.

III.7.3 Limites et Perspectives :

Malgré les excellentes performances obtenues, plusieurs limites méritent d'être mentionnées :

- **Dépendance aux données d'apprentissage** : La qualité de la correction dépend fortement de la représentativité des données d'apprentissage. Des environnements très différents de ceux vus pendant l'apprentissage pourraient dégrader les performances.
- **Dimension 2D** : Cette étude se limite à la localisation en deux dimensions. Une extension à la localisation 3D (X, Y, Z) nécessiterait l'ajout de la coordonnée Z dans les entrées et sorties du réseau.
- **Temps réel** : L'apprentissage est réalisé hors ligne. Pour une application en temps réel, il faudrait envisager des architectures de réseaux plus légères ou des techniques d'apprentissage incrémental.
- **Multi-objets** : L'approche actuelle traite chaque objet indépendamment. Une approche collaborative exploitant les corrélations spatiales entre objets pourrait améliorer davantage les performances.

III.8 Conclusion :

Ce chapitre a présenté l'implémentation et les résultats de simulation de l'approche d'apprentissage supervisé appliquée à la correction des trajectoires UWB indoor. Les principales conclusions sont les suivantes :

- **Efficacité démontrée** : Les réseaux de neurones à propagation avant avec 15 neurones cachés permettent une amélioration significative de la précision de localisation par rapport aux mesures UWB-TOA brutes et au filtre de Kalman.

- **Compensation des non-linéarités** : L'approche par IA compense efficacement les erreurs dues aux multi-trajets et aux conditions de non-ligne-de-vue, qui constituent les principales limitations des systèmes UWB indoor.
- **Robustesse** : Les résultats obtenus sur trois trajectoires distinctes confirment la robustesse et la généralisation de l'approche proposée.
- **Avantages confirmés** : L'apprentissage supervisé offre une solution prometteuse pour améliorer la localisation indoor UWB, surpassant les méthodes classiques de filtrage dans les environnements non linéaires.

Ces résultats valident l'hypothèse de départ selon laquelle l'intelligence artificielle, et plus particulièrement l'apprentissage supervisé par réseaux de neurones, constitue une approche pertinente et efficace pour améliorer la précision des systèmes de localisation UWB en environnement indoor.

Conclusion générale

Conclusion générale

En guise de conclusion, ce travail de recherche nous a permis de mettre en lumière l'un des défis technologiques majeurs dans le domaine de la navigation et du suivi des objets, à savoir la réalisation d'un système de localisation indoor à la fois précis et stable. Bien que la technologie UWB (*Ultra-Wideband*) ait démontré une efficacité remarquable grâce à sa précision centimétrique et sa forte capacité de pénétration des obstacles, son application pratique reste conditionnée par la gestion des distorsions non linéaires des signaux. Ces dernières, causées par les phénomènes de multi-trajets, l'absence de ligne de visée directe (NLOS) et le bruit ambiant, représentent des défis complexes que les méthodes de calcul géométriques traditionnelles, telles que la TOA et la TDOA, peinent à résoudre efficacement à elles seules.

Pour surmonter ces limitations, l'intégration de **l'Intelligence Artificielle**, et plus particulièrement des techniques d'**Apprentissage Supervisé**, a constitué un véritable saut qualitatif et une solution de rupture. Les résultats obtenus lors de l'étape de simulation ont mis en évidence la capacité des algorithmes d'apprentissage intelligent à modéliser les relations complexes et non linéaires des données, notamment à travers la mise à jour des coefficients de pondération. Cela s'est traduit de manière concrète par les courbes d'estimation des coordonnées spatiales (X, Y, Z) des objets suivis. Les algorithmes (tels que XGBoost ou d'autres classifieurs) ont réussi avec succès à filtrer le bruit et à corriger les dérives de trajectoire causées par les multi-trajets indirects, surpassant ainsi les solutions classiques grâce à leur grande flexibilité et leur forte capacité de prédiction des paramètres.

Référence bibliographique

Liste des références :

- [1] Hafashimana, E. (2024). Conception et mise en œuvre d'un système de navigation intérieure économique utilisant des technologies open-source dans les bâtiments universitaires (Mémoire de maîtrise). Université du Québec à Chicoutimi, Canada.
- [2] Almanza-Ojeda, D. L. (2009). Détection et suivi d'objets mobiles perçus depuis un capteur visuel embarqué (Thèse de doctorat). Université de Technologie de Compiègne, France.
- [3] Evennou, F. (2007). Techniques et technologies de localisation avancées pour les environnements intérieurs (Thèse de doctorat). Université Joseph Fourier Grenoble I, France.
- [4] Nehnouch, C., Guezouri, M., & Keche, M. (2013). Réalité augmentée : Localisation d'un mobile dans un environnement indoor. *Communication Science & Technologie*, (11), 5–6.
- [5] Tinard, P. (2007). Schéma de principe de la localisation par GPS (trilatération spatiale). ResearchGate. https://www.researchgate.net/figure/Schema-de-principe-de-la-localisation-par-GPS-trilateration-spatiale-d1-d2-et-d3-sont_fig7_280791028
- [6] Marais, J., Betaille, D., Meurie, C., Ambellouis, S., & Flancquart, A. (2015). Algorithmes embarqués de localisation outdoor pour les véhicules en milieu urbain et algorithme embarqué de fusion GNSS et carte numérique (Rapport de recherche No. hal-01663969). IFSTTAR.
- [7] Technische Universität Chemnitz. (n.d.). SmartLoc project. <https://www.tu-chemnitz.de/etit/proaut/en/research/smartloc.html>
- [8] TelecomTuto. (n.d.). Différence entre C/N0 et SNR en télécommunications. <https://telecomtuto.com/difference-entre-c-n0-et-snr-en-telecommunications/>
- [9] Vervisch-Picois, A. (2022). Systèmes de localisation en milieu contraint et de leurre GNSS (Habilitation à diriger des recherches). Institut Polytechnique de Paris.

- [10] Pardiñas-Mir, J. A. (2012). Contribution à l'étude de la détection des signaux UWB : Étude et implémentation d'un récepteur ad hoc multicateurs. Applications indoor de localisation (Thèse de doctorat). Télécom SudParis & Université Pierre et Marie Curie.
- [11] Santamaría-Pedron, J. C., Berkvens, R., Miralles, I., Reaño, C., & Torres-Sospedra, J. (2025). Machine learning integration in ultra-wideband-based indoor positioning systems: A comprehensive review. *Electronics*, 15(1), 181.
- [12] Modaberi, S. (2025). Real-time UWB indoor localization: Deep learning approaches for NLoS mitigation and latency compensation (Doctoral dissertation). University of Calgary.
- [13] Wang, L., et al. (2025). Improved UWB-based indoor positioning system via NLOS classification and error mitigation. *Engineering Science and Technology, an International Journal*.
- [15] Russell, S., & Norvig, P. (2020). Artificial intelligence: A modern approach (4th ed.). Pearson.
- [16] Mitchell, T. M. (1997). Machine learning. McGraw-Hill.
- [17] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [18] Alshehri, M. A. (2024). A survey of application of machine learning in wireless indoor positioning systems. arXiv. <https://arxiv.org/abs/2412.08438>
- [19] Han, J., Kamber, M., & Pei, J. (2011). Data mining: Concepts and techniques (3rd ed.). Morgan Kaufmann.
- [20] Sutton, R. S., & Barto, A. G. (2018). Reinforcement learning: An introduction (2nd ed.). MIT Press.
- [21] Marano, S., Gifford, W. M., Wymeersch, H., & Win, M. Z. (2010). NLOS identification and mitigation for localization based on UWB experimental data. *IEEE Journal on Selected Areas in Communications*, 28(7), 1026–1035. <https://doi.org/10.1109/JSAC.2010.100908>

- [22] Zhang, S., Li, Y., Gao, H., & Wang, P. (2020). UWB indoor localization using deep learning LSTM networks. *Applied Sciences*, 10(18), 6290. <https://doi.org/10.3390/app10186290>
- [23] Bahl, P., & Padmanabhan, V. N. (2000). RADAR: An in-building RF-based user location and tracking system. In *Proceedings of IEEE INFOCOM* (Vol. 2, pp. 775–784). <https://doi.org/10.1109/INFCOM.2000.832252>
- [24] Gezici, S., & Poor, H. V. (2009). Position estimation via ultra-wide-band signals. *Proceedings of the IEEE*, 97(2), 386–403. <https://doi.org/10.1109/JPROC.2008.2008840>
- [25] Li, X. (2024). UWB indoor localization method based on neural network multi-classification for NLOS distance correction. *Sensors*, 24(15), 4890.
- [26] Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- [27] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- [28] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [29] Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
- [30] Wang, Y., & Yang, L. (2024). Analysis of machine learning-based NLOS signal identification algorithm for UWB indoor localization using CIR waveform features. *ISPRS Archives*, XLVIII-4/W9-2024, 195–200. <https://doi.org/10.5194/isprs-archives-XLVIII-4-W9-2024-195-2024>
- [31] Zhang, Y., Chen, X., & Li, W. (2023). A method for UWB localization based on CNN-SVM and hybrid locating algorithm. *Information*, 14(3), 189. <https://doi.org/10.3390/info14030189>

