

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université 8 Mai 1945 – Guelma
Faculté des Sciences et de la Technologie
Département d'électroniques et des télécommunications

Réf /2025



MEMOIRE

Présenté pour l'obtention du **diplôme** de **MASTER Académique**

Domaine : Sciences et Technologie

Filière : Électronique

Spécialité : Instrumentations

Par : SMAALI Bochra

Thème

La géolocalisation en environnement intérieur basée sur le signal Wi-Fi

Sous la direction de :

DR. ELAGGOUNE Hocine

Année Universitaire : 2024/2025

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ
وَالْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ
وَالصَّلَاةُ وَالسَّلَامُ عَلَى مَنْ بُعِثَ رَحْمَةً لِلْعَالَمِينَ وَعَلَى آلِهِ وَصَحْبِهِ أَجْمَعِينَ.

اللهم لك الحمد حتى ترضى، ولك الحمد إذا رضيت، ولك الحمد بعد الرضا، ولك الحمد أبداً أبداً

إلى والدي العزيز السيد مبارك سماعلي، فخر اسمي، وسند حياتي، جزاك الله عني خير الجزاء

إلى أُمي الحبيبة، بدعواتك نجوت، وبحنانك كنت الحياة والأمان

إلى أخي أيوب وأختي وجدان، حبيبي أنتما سعادتي ونعم الشدّ والعصـد

إلى عمتي الغالية، أُمي الثانية، حفظك الله وجزاك عني خيراً

إلى خطيبي باسم، سندي ومحفزي نعم العوض، شكراً لإيمانك الثابت بي و لوجودك الذي منحني القوة

إلى صويحبات القرآن: يقين وفاطمة الزهراء، وشيختي الفاضلة أُمي عقيلة حجاجي، وإلى مقرأة "اقرأ وارتق"

فجزى الله القائمين عليها خير الجزاء

إلى صديقاتي: إيمان، شروق، سمية، وزملائي في هذا المشوار، شكراً لكل لحظة دعمكم لي

إلى قلوب صغيرة تنبض بالبراءة والجمال إلى أحبابي الصغار أحمد، مريم... أحمد، مريم، زهور حياتنا

وبسمتنا الدائمة أنتم النور والبهجة

إلى غزاة وأهلها الصامدين، الصابرين الذين علمونا معنى الثبات والكرامة لهم من قلبي دعاء لا ينقطع

وسلاماً لا يزول

وإلى قطي الحبيب مرمر، رفيق الهدوء ولحظات التعب

وختاماً أرفع أكف الضراعة بالدعاء حمداً وتسييحاً

﴿سُبْحَانَ رَبِّكَ رَبِّ الْعِزَّةِ عَمَّا يَصِفُونَ (180) وَسَلَامٌ عَلَى الْمُرْسَلِينَ (181) وَالْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ (182)﴾

Remercîment -----

Louange à ALLAH le tout Puissant, qui nous a permis d'achever ce mémoire.

Je tiens à exprimer ma profonde gratitude à mes encadrants, **M. ELAGGOUNE Hocine** enseignant chercheur de l'université 08 Mai 1945 Guelma et **M. MESSAADIA Mourad**, enseignant chercheur de l'université du Bahreïn pour la confiance qu'ils m'ont témoignée, leur disponibilité constante, leur accompagnement rigoureux et leur pédagogie. Leur implication tout au long de ce travail a grandement contribué à faire de ce sujet de recherche une expérience intellectuelle aussi stimulante qu'enrichissante.

Je tiens à remercier aussi le jury : **M. le Pr. BOUKAACHE Abdenour**, président et **M. le Dr. GRIOUZ Badreddine**, Examineur, qui m'ont fait l'honneur d'accepter d'évaluer ce travail.

Je remercie tous les enseignants qui ont participé à ma constitution, comme je remercie mes collègues et amis de promotion pour leur soutien, leurs retours critiques, leur bonne humeur et les nombreuses discussions constructives qui ont jalonné ces mois de travail.

Je remercie tous les responsables et les administrateurs de la faculté des Sciences et de la Technologie, en particulier du département Génie Electrotechnique et Automatique, université **08 Mai 1945 Guelma** de leurs collaborations.

Je remercie ma famille pour son soutien indéfectible, sa patience et ses encouragements, sans lesquels cette aventure intellectuelle n'aurait pas été possible.

Tous mes remerciements pour les travailleurs du domaine d'éducatifs et d'enseignements qui font leur devoir sans attendre aucune récompense de n'importe qui sauf Dieu.

En fin, mes remerciements vont à tous ceux qui m'ont soutenu ou qui, d'une manière ou d'une autre, ont contribué à l'élaboration de ce travail.

SMAALI Bochra

ملخص:

تحديد الموقع في بيئة داخلية (Indoor Geolocation) أضحي ضرورة ملحة في العديد من الميادين، مثل تحديد الموقع او التنقل داخل المباني المتفرعة، وتتبع الاهداف، وتحسين الأداء ضمن البيئات الذكية.

وبما أنّ أنظمة تحديد المواقع التقليدية (GPS) تُعدّ غير فعّالة داخل الأبنية، بسبب ضعف الإشارة الناتج عن الحواجز المادية كالجدران والأسقف، الذي يؤدي إلى انخفاض دقة التحديد. جاءت فكرة هذا البحث، الذي يقترح منهجية لتحديد المواقع الداخلية والتي تعتمد على قوة إشارة شبكات الواي فاي (Wi-Fi)، حيث يتم استغلال البنية التحتية اللاسلكية القائمة والقياسات الفعلية للإشارة بهدف تقديم تموضع دقيق وفعال داخل المباني.

الهدف الرئيسي من هذا العمل هو تطوير وتقييم نماذج ذكية قادرة على تحديد الموقع الداخلي بدقة، انطلاقاً من بيانات واقعية لإشارات الواي فاي.

الكلمات المفتاح: التموقع الداخلي؛ التموقع الخارجي؛ واي فاي "Wi-Fi"؛ نظام تحديد المواقع العالمي "GPS"؛ نموذج الانحدار الذاتي المتكامل المتوسط المتحرك "ARIMA"؛ الغابة العشوائية "RF"؛ وحدة التكرار ذات البوابات "GRU"؛ نظام التموقع الداخلي "IPS".

Abstract:

Indoor geolocation has become increasingly crucial for a wide range of applications, including navigation within large buildings, asset tracking, and enhancing user experiences in smart environments. Traditional Global Positioning System (GPS) technologies are largely ineffective indoors due to signal degradation caused by walls, ceilings, and other obstructions.

This project explores an indoor positioning method based on Wi-Fi signal strength (Received Signal Strength Indicator, RSSI), leveraging existing wireless infrastructure to deliver accurate and cost-effective indoor localization.

Keywords: *Indoor Geolocation; Outdoor Geolocation; Wi-Fi; GPS; ARIMA (AutoRegressive Integrated Moving Average); Random Forest; GRU (Gated Recurrent Unit); indoor positioning system (IPS).*

Résumé:

La géolocalisation en environnement intérieur (Indoor Geolocation) est devenue essentielle pour diverses applications, notamment la navigation dans les grands bâtiments, le suivi des biens et l'amélioration de l'expérience des utilisateurs dans les environnements intelligents. Les systèmes GPS (Global Positioning System) traditionnels sont inefficaces en intérieur en raison des interférences causées par les murs et les plafonds. Ce projet propose une méthode de géolocalisation interne basée sur l'intensité du signal Wi-Fi (Wireless Fidelity), en tirant parti de l'infrastructure existante et des mesures du signal pour fournir un positionnement intérieur précis.

Mots clés : *Géolocalisation intérieur ; Géolocalisation extérieure ; Wi-Fi; GPS; ARIMA ; Random Forest ; GRU ; Système de positionnement intérieur (SPI).*

Table des matières

ملخص:	I
Abstract:	II
Résumé:	III
Liste des figures	VII
Liste des Tableaux	IX
Acronymes	X
Introduction générale	1
1. Contexte.....	1
2. Problématique.....	1
3. Objectifs	2
4. Contributions	2
5. Matériel mise en œuvre pour la réalisation de nos expériences	3
6. Organisation du mémoire	3
Chapitre 1 : État de l'art	4
1.1. Introduction	4
1.2. Problématique de la géolocalisation intérieure	4
1.2.1. Limites du GPS en intérieur.....	4
1.2.2. Enjeux de la localisation en intérieur	5
1.3. Technologies de géolocalisation intérieure.....	6
1.3.1. Bluetooth Low Energy (BLE) (beacons)	6
1.3.2. Wi-Fi.....	7
1.3.3. Bande Ultra Large (en anglais : Ultra Wideband - UWB).....	8
1.3.4. Zigbee	8
1.3.5. RFID (Radio Frequency Identification).....	9
1.3.6. Li-Fi (Light Fidelity)	9
1.3.7. Ultrasons	10
1.4. Synthèse comparative des technologies de géolocalisation intérieure	11
1.5. Wi-Fi comme technologie de géolocalisation	12
1.5.1. Principes de fonctionnement	13
1.5.2. Avantages et limitations.....	13
1.6. Travaux récents et tendances	14
1.6.1. Amélioration de la précision et réduction des erreurs de positionnement	14

1.6.2. Utilisation de l'intelligence artificielle (IA) et de l'apprentissage automatique	15
1.6.3. Technologies émergentes et nouvelles approches	16
1.7. Positionnement du projet.....	17
1.8. Conclusion.....	18
Chapitre 2 : Techniques de Géolocalisation à base de Wi-Fi	19
2.1. Introduction	19
2.2. Principes physiques du Wi-Fi pour la géolocalisation	20
2.2.1. Technique basée sur le RSS (Received Signal Strength)	20
2.2.2. Angle d'arrivée (AOA)	21
2.2.3. Technique basée sur le temps.....	22
2.2.4. Technique Map-Matching	26
2.2.5. CSI (Channel State Information)	26
2.2.6. Propriétés radio des environnements intérieurs	26
2.3. Méthodes de géolocalisation Wi-Fi	27
2.3.1. Trilatération (ou triangulation de distance)	27
2.3.2. Triangulation angulaire (AoA)	28
2.3.3. Fingerprinting (empreinte de signal)	28
2.3.4. Méthodes hybrides (Wi-Fi + capteurs).....	29
2.3.5. Approches basées sur l'intelligence artificielle	30
2.4. Conclusion.....	30
Chapitre 3 : Implémentation et Résultats expérimentaux.....	31
3.1. Cadre expérimental.....	31
3.1.1. Description de l'environnement de test.....	31
3.1.2. Équipement utilisé.....	31
3.1.3. Protocole de collecte des données.....	33
3.1.4. Objectifs de l'analyse	33
3.2. Prétraitement des données.....	33
3.2.1. Structure des données collectées	33
3.2.2. Alignement des mesures et des coordonnées	34
3.2.3. Normalisation des données	34
3.2.4. Découpage des données.....	34
3.3. Implémentation des modèles ARIMA, Random Forest et GRU.....	35
3.3.1. Modèle ARIMA (AutoRegressive Integrated Moving Average)	35

3.3.2. Modèle Random Forest.....	37
3.3.3. Modèle GRU (Gated Recurrent Unit)	37
3.3.4. Résumé des caractéristiques.....	38
3.4. Évaluation des performances des modèles.....	39
3.4.1. Métriques utilisées.....	39
3.4.2. Environnement de test	40
3.4.3. Collecte des données.....	41
3.5. Résultats	41
3.6. Synthèse et Discussion.....	56
3.7. Conclusion.....	58
Conclusion et perspectives	60
<i>Bibliographies</i>	63

Liste des figures

Figures	Pages
Fig 1. 1 Constellation des satellites (GPS)	5
Fig 1. 2 Bluetooth et distance de connexion avec les appareils les plus populaires	6
Fig 2. 1 Technologie de propagation RSS-radio.	20
Fig 2. 2 Technique AOA avec trois mesures angulaires	22
Fig 2. 3 TOA à trois positions	24
Fig 2. 4 Localisation et détection de proximité basées sur TDOA.	24
Fig 2. 5 RTOF pour les déterminations de la géolocalisation d'un smartphone.	25
Fig 3. 1 Application "Wi-Fi SweetSpots"	32
Fig 3. 2 Modem-routeur D-Link DSL-224 N300	32
Fig 3. 3 Architecture fonctionnelle d'un modèle ARIMA	36
Fig 3. 4 Structure d'une unité récurrente à portes (GRU) de base	38
Fig 3. 5 Lieu d'expérimentation	40
Fig 3. 6 Mesure de l'erreur RMSE (en dBm) d'emplacements (P1 : P22)	42
Fig 3. 7 Prédiction du signal RSSI pour P22 à l'aide des modèles ARIMA, Random Forest et GRU.	43
Fig 3. 8 Prédiction du signal RSSI pour P21 à l'aide des modèles ARIMA, Random Forest et GRU.	44
Fig 3. 9 Prédiction du signal RSSI pour P20 à l'aide des modèles ARIMA, Random Forest et GRU.	44
Fig 3. 10 Prédiction du signal RSSI pour P19 à l'aide des modèles ARIMA, Random Forest et GRU.	45
Fig 3. 11 Prédiction du signal RSSI pour P18 à l'aide des modèles ARIMA, Random Forest et GRU.	46
Fig 3. 12 Prédiction du signal RSSI pour P17 à l'aide des modèles ARIMA, Random Forest et GRU.	46
Fig 3. 13 Prédiction du signal RSSI pour P16 à l'aide des modèles ARIMA, Random Forest et GRU.	47

Fig 3. 14 Prédiction du signal RSSI pour P15 à l'aide des modèles ARIMA, Random Forest et GRU.	48
Fig 3. 15 Prédiction du signal RSSI pour P14 à l'aide des modèles ARIMA, Random Forest et GRU.	49
Fig 3. 16 Prédiction du signal RSSI pour P13 à l'aide des modèles ARIMA, Random Forest et GRU	50
Fig 3. 17 Prédiction du signal RSSI pour P12 à l'aide des modèles ARIMA, Random Forest et GRU.	50
Fig 3. 18 Prédiction du signal RSSI pour P11 à l'aide des modèles ARIMA, Random Forest et GRU.	50
Fig 3. 19 Prédiction du signal RSSI pour P10 à l'aide des modèles ARIMA, Random Forest et GRU.	51
Fig 3. 20 Prédiction du signal RSSI pour P9 à l'aide des modèles ARIMA, Random Forest et GRU.	52
Fig 3. 21 Prédiction du signal RSSI pour P8 à l'aide des modèles ARIMA, Random Forest et GRU.	52
Fig 3. 22 Prédiction du signal RSSI pour P7 à l'aide des modèles ARIMA, Random Forest et GRU.	52
Fig 3. 23 Prédiction du signal RSSI pour P6 à l'aide des modèles ARIMA, Random Forest et GRU.	53
Fig 3. 24 Prédiction du signal RSSI pour P5 à l'aide des modèles ARIMA, Random Forest et GRU.	54
Fig 3. 25 Prédiction du signal RSSI pour P4 à l'aide des modèles ARIMA, Random Forest et GRU.	54
Fig 3. 26 Prédiction du signal RSSI pour P3 à l'aide des modèles ARIMA, Random Forest et GRU.	54
Fig 3. 27 Prédiction du signal RSSI pour P2 à l'aide des modèles ARIMA, Random Forest et GRU.	55
Fig 3. 28 Prédiction du signal RSSI pour P1 à l'aide des modèles ARIMA, Random Forest et GRU.	55

Liste des Tableaux

Tableaux		Pages
Tableau.1. 1	Tableau comparatif des technologies de géolocalisation intérieure	11
Tableau.3. 1	Signification des grandeurs du modèle GRU	38
Tableau.3. 2	Caractéristiques des méthodes ARIMA ; Random Forest ; et GRU.	39
Tableau.3. 3	Exemple d'extrait représentatif des mesures RSSI collectées aux différents emplacements intérieurs	41

Acronymes

AOA:	Angle Of Arrival
AP:	Access Point
ARIMA	AutoRegressive Integrated Moving Average
AR	AutoRegressive
AWFP:	Adaptive Wi-Fi FTM Positioning
BLE:	Bluetooth Low-Energy
BS:	Base Stations
EKF:	Extended Kalman Filter
FTM:	Fine Time Measurement
GNSS:	Global Satellite Navigation System
GPS:	Global Positioning System
GRU	Gated Recurrent Unit
IEEE:	Institute of Electrical and Electronics Engineers
IMU:	Inertial Measurement Units
IPS:	Indoor Positioning System
kNN:	k-Nearest Neighbor
LTE:	Long Term Evolution
MA	Moving Average
NLOS:	Non-Line-Of-Sight
PDR:	Pedestrian Dead Reckoning
RF:	Radio Frequency
RFID:	Radio frequency identification
RN	Receiver Node
RSS:	Really Simple Syndication
SLAM:	Simultaneous Localization and Mapping
SSID:	Service Set Identifier

TDOA: Time Difference Of Arrival

TOA: Time Of Arrival

UWB: Ultra-Wide Band

Wi-Fi Wireless Fidelity

WLAN: Wireless Local Area Network

WLS: Weighted Least-Squares

WSN: Wireless Sensor Networks

Introduction générale

1. Contexte

La géolocalisation remonte à l'antiquité. Depuis son existence, l'être humain a essayé d'inventer des moyens de localisations. Parmi ces moyens : la connaissance de la position par la position des étoiles, les phares (maritimes depuis l'antiquité, et aéronautiques depuis les années 1920), les sextants, les satellites [1].

La géolocalisation a connu une évolution incontournable depuis la fin du XXe siècle, d'où l'invention des systèmes de trilatération, d'abord terrestres puis par satellites avec le GPS (Global Positioning System), qui ont pris domination, en raison de leur précision et de leur couverture [2].

Malgré ce développement considérable dans le domaine de géolocalisation, Les systèmes GPS traditionnels restent inefficaces en intérieur des emmeubles en raison des interférences causées par les parois, les murs et les plafonds. C'est pour cela qu'on a entamé la recherche et la proposition d'une méthode de géolocalisation interne basée sur l'intensité du signal Wi-Fi, en tirant parti de l'infrastructure existante et des mesures du signal pour fournir un positionnement intérieur précis.

2. Problématique

La demande de positionnement intérieur précis augmente dans des domaines tels que la vente au détail, les musées, et la sécurité. Les applications comprennent le guidage des utilisateurs dans les aéroports, la localisation des biens dans les entrepôts et l'assistance aux intervenants d'urgence dans les sites complexes.

Le positionnement Wi-Fi exploite les caractéristiques du signal, telles que l'indicateur d'intensité du signal reçu (RSSI) et le temps de vol (ToF), pour estimer l'emplacement d'un appareil. En raison de la disponibilité généralisée des points d'accès Wi-Fi, cette approche est

rentable et présente une faible empreinte infrastructurelle par rapport aux systèmes de positionnement spécialisés tels que le Bluetooth ou Ultra-Wideband.

3. Objectifs

Nos recherches portent sur le développement et l'évaluation d'un algorithme géospatial interne utilisant les signaux Wi-Fi, donc les objectifs sont les suivants :

- Évaluer l'efficacité des modèles d'apprentissage automatique pour prédire les emplacements intérieurs sur la base du RSSI Wi-Fi.
- Comparer les performances de différents algorithmes de positionnement tels que l'empreinte digitale, la trilatération et les méthodes basées sur l'apprentissage automatique.
- Développer une solution de géolocalisation basé sur le Wi-Fi pour un positionnement intérieur précis.
- Implémenter et/ou simuler la solution proposée.
- Evaluer la performance de la solution proposée.

4. Contributions

Ce travail apporte de nombreuses contributions précieuses à la géolocalisation interne :

- Analyse des techniques basé sur le Wi-Fi pour la localisation interne, en mettant l'accent sur leurs forces et leurs faiblesses.
- Développement d'un nouvel algorithme d'intégration de données qui améliore la précision de la localisation grâce au signal Wi-Fi.
- Comparaison des résultats obtenus avec les méthodes actuelles et apport d'informations sur les améliorations futures et les tendances de recherche possibles.

5. Matériel mise en œuvre pour la réalisation de nos expériences

Pour bien mener nos Travaux de recherches, nous avons bénéficié des ressources et outils suivants :

- **Appareils :**
 - **Ordinateur** : de Processeur Intel(R) Core(TM) i7-7500U CPU @ 2.70GHz 2.90 GHz, avec RAM de 8,00 Go.
 - **Modem** : Modem Router D-Link sans-fil dsl-224 N300 VDSL2/ADSL2+
- **Logiciel** : Python dans ses différentes bibliothèques Tensorflow ; pandas ; et Matplotlib pour modéliser et traiter les données.
- **Environnement de mesure** : le lieu de l'expérimentation est une maison, constitué d'un rez-de-chaussée et un étage (chaque un des deux est 6 chambres par étage), chaque pièce a été subdivisée en deux zones de mesure(**Fig 3. 5**). Pour chaque chambre deux point de mesures fixes ont été sélectionnés. Au total, **22 points** de mesures fixes.

6. Organisation du mémoire

Ce manuscrit est structuré autour de trois chapitres : après avoir introduit l'état de l'art (**chapitre 1**), le **chapitre 2** est dédié à notre approche proposée à base de la modélisation et à l'apprentissage automatique. Le **chapitre 3** est consacré à l'implémentation et l'évaluation des performances de l'approche proposée. Enfin, nous clôturons ce mémoire par une conclusion générale et des perspectives.

Chapitre 1 : État de l'art

1.1. Introduction

Un système de positionnement intérieur (Indoor Geolocation) est un système de détection et localisation de l'emplacement d'une cible dans un environnement intérieur, là où les systèmes les plus répandus dans le domaine de la géolocalisation comme le GPS montrent leurs limites [3]-[4]. Avec les progrès incontournables des techniques et des technologies sans fil et l'émergence des bâtiments intelligents, les besoins en systèmes de localisation précis, fiables et peu coûteux ont devenus plus exigeants que jamais.

Parmi les techniques les plus populaires utilisées dans un environnement intérieur, on trouve le réseau Wi-Fi, qui sont largement disponibles et déployés dans la plupart des bâtiments [5].

Ce chapitre fournit un aperçu des approches, technologies et techniques existantes utilisées pour la géolocalisation en environnement intérieur, avec un accent particulier sur l'utilisation du signal Wi-Fi.

1.2. Problématique de la géolocalisation intérieure

1.2.1. Limites du GPS en intérieur

La fin du XXe siècle a connu la création des systèmes de trilatération, d'abord terrestres puis par satellites avec le GPS (Global Positioning System), qui ont pris domination, en raison de leur précision et de leur couverture [2].

Le système GPS est utilisé dans l'estimation de la position d'une cible dans un environnements extérieurs (Outdoor), l'estimation de la position extérieurs est généralement résolue à l'aide d'un système mondial de navigation par satellite (Global Satellite Navigation System GNSS), c-à-d un système qui repose sur la réception de signaux satellites (voir **Fig 1.1**) [5]-[6]. Or, dans des environnements intérieurs, ces signaux sont fortement atténués ou bloqués par les murs, plafonds et autres structures, entraînant une perte de précision ou une

absence totale de localisation. Cela veut dire que dans un environnement intérieur, nous devons encore définir une norme de système de positionnement ou de localisation qui peut être appliquée dans le monde entier et dans différents contextes [7].




Fig 1. 1. Constellation des satellites (GPS)

1.2.2. Enjeux de la localisation en intérieur

Les systèmes de positionnement en intérieur (*Indoor Positioning System- IPS*) s'appuie sur plusieurs technologies de localisation : balises Bluetooth (*beacons*), puces RFID, signaux Wi-Fi et UWB pour les technologies radio, mais aussi les signaux ultrasons ou le champ magnétique. Selon leur forme et l'usage souhaité, elles sont disséminées dans le bâtiment ou cartographiées. Les signaux qu'elles émettent sont ensuite captés par divers supports mobiles, comme votre smartphone ou une tablette tactile.

On peut constater que les besoins de la géolocalisation indoor sont multiples :

- Navigation assistée dans les hôpitaux, aéroports ou centres commerciaux
- Suivi des équipements dans l'industrie ou la logistique
- Services contextuels dans les smart buildings ou musées
- Sécurité (localisation des personnes en situation d'urgence)

1.3. Technologies de géolocalisation intérieure

La Géolocalisation intérieure, aussi connue sous l'appellation en anglais "**indoor positioning**" est d'une grande importance et trouve son application dans divers domaines. Elle facilite l'orientation et la localisation des utilisateurs, tout en permettant aux entreprises de proposer des services innovants à leurs clients [8].

La Géolocalisation intérieure s'appuie sur une combinaison de diverses technologies. Les technologies couramment utilisées incluent le Bluetooth Low Energy (BLE), le Wi-Fi, les balises RFID, la bande ultra-large (UWB), les signaux acoustiques, et les systèmes inertiels [8]-[10].

1.3.1. Bluetooth Low Energy (BLE) (beacons)

Le Bluetooth est une technologie à courte portée fondamentale fonctionnant dans 2.4 Bande de fréquence GHz, conçu pour connecter les appareils à moins de 10 mètres (Fig 1. 2) [11].




Fig 1. 2. Bluetooth et distance de connexion avec les appareils les plus populaires

L'intérêt du Bluetooth pour des applications de géolocalisation est apparu en 2010 avec la naissance du « Bluetooth Low Energy » (BLE, version 4.0) aussi couramment appelé « Bluetooth Smart ».

Cette nouvelle norme, spécialement développée pour des applications autour de l'internet des objets, propose notamment une consommation de puissance extrêmement réduite. Elle permet de fait la mise en place de systèmes pérennes et autonomes.

En particulier les systèmes de localisation Bluetooth s'appuient sur des balises sans fil nommées « beacons » dont la portée d'émission avoisine généralement quelques dizaines de mètres [12]-[13].

1.3.2. Wi-Fi

Le Wi-Fi est un ensemble de protocoles de communication sans fil régis par les normes du groupe IEEE 802.11 (ISO/CEI 8802-11). Elle permet un accès internet haut débit et une connectivité de l'appareil à travers 2.4 GHz, 5 GHz, et 6 GHz Bandes de fréquences. Avec une gamme intérieure typique de 30 à 100 mètres, il prend en charge les débits de données jusqu'à 9.6 Gbps.

Le Wi-Fi est aujourd'hui très utilisé dans les solutions de localisation indoor pour son implémentation simple et bas coût. Le principe de positionnement ici à l'œuvre repose sur la force du signal reçu (RSS).

Comme le suggère la méthode, l'utilisateur accède donc aux données de puissance des points d'accès environnants. Il n'est toutefois pas nécessaire de se connecter aux réseaux.

GHERIB, K. (2021) a proposé un système de navigation utilisant la combinaison des capteurs inertiels et des signaux Wi-Fi, avec l'intégration des algorithmes de filtrage (le filtre Kalman). Ce travail a conduit à l'amélioration de la précision des solutions de navigation en réduisant les erreurs liées à l'intensité du signal et aux capteurs inertiels.

On peut mentionner que le signal Wi-Fi, et BLE peut être présenté comme une technologie alternative ou complémentaire, utile si l'on souhaite améliorer la précision ou ajouter des fonctionnalités interactives.

1.3.3. Bande Ultra Large (en anglais : Ultra Wideband - UWB)

Bande Ultra Large (UWB) est une technologie sans fil qui est basée sur la transmission d'impulsions de très courte durée, souvent inférieure à la nanoseconde, et sur un large spectre de fréquence (500 MHz à plusieurs GHz), permettant une localisation très précise, de l'ordre de quelques centimètres.

Parmi les travaux récents reposant sur la technologie UWB, on trouve : Tiemann, J., & Wietfeld, C. (2017) qui ont présenté un système de navigation évolutif pour drones utilisant la différence de temps d'arrivée (TDoA), et grâce au filtre Kalman, ils ont trouvé que l'erreur de précision était de 10 cm [14].

Il est pertinent de mentionner UWB comme technologie de référence en précision, mais moins accessible que le Wi-Fi, notamment pour les environnements qui ne disposent pas déjà de l'infrastructure ou du matériel compatible.

1.3.4. Zigbee

Zigbee est une technologie sans fil développée en tant que norme ouverte de connectivité du marché mondial pour répondre aux besoins uniques des réseaux de données sans fil à faible coût et à faible consommation d'énergie (IoT).

Le Zigbee fonctionne principalement dans la Bande 2.4 GHz (soutenir également 868 MHz et 915 MHz régionalement). Il est conçu également pour les gammes de 10 à 100 mètres. En plus de ça, il offre un débit de données de 250 Kbps, prioriser la fiabilité sur la vitesse pour les applications telles que les capteurs de maison intelligente, Et l'automatisation industrielle.

Zigbee peut être utilisé pour estimer la position en analysant l'intensité du signal (RSSI), mais n'est pas conçu à l'origine pour le positionnement précis. Il peut cependant être utile dans des environnements restreints et bien contrôlés, ou comme complément à d'autres technologies dans un système de fusion de capteurs.

1.3.5. RFID (Radio Frequency Identification)

La RFID est une technologie de communication sans fil qui permet d'identifier à distance des objets ou des personnes à l'aide d'étiquettes (tags) munies de puces électroniques, et de lecteurs capables de lire ces puces. Elle repose sur la transmission de données via des ondes radio, sans contact direct ni ligne de vue.

Bien que la RFID ne soit pas une technologie de positionnement active par défaut, elle peut être exploitée pour la localisation approximative lorsqu'un réseau dense de lecteurs est déployé dans un espace donné.

Comparée à d'autres technologies de positionnement intérieur, telles que le WLAN, le Bluetooth, l'UWB (Ultra Wideband), l'infrarouge ou l'ultrason, la RFID est souvent considérée comme plus économique et pratique [15]-[17].

1.3.6. Li-Fi (Light Fidelity)

Le Li-Fi (Light Fidelity) est une technologie de communication sans fil qui utilise la lumière visible, les infrarouges ou l'ultraviolet pour transmettre des données. Elle repose sur la modulation rapide de l'intensité lumineuse émise par une source LED. Contrairement au Wi-Fi qui utilise des ondes radio, le Li-Fi fonctionne via le spectre optique et nécessite une ligne de vue directe pour la transmission [18].

Bien que principalement conçue pour la transmission de données, cette technologie peut être adaptée à la géolocalisation intérieure avec une précision très fine, grâce à la détection du signal lumineux reçu.

Le Li-Fi est particulièrement adapté aux environnements nécessitant une précision centimétrique, notamment dans le domaine de la navigation intérieure ou de la réalité augmentée. Il est cependant très dépendant des conditions lumineuses et ne peut pas remplacer seul les autres technologies dans les environnements complexes ou multi-obstacles.

Parmi, les travaux récents utilisant la Li-Fi en navigation intérieure, on trouve :

- "A Survey on Indoor Visible Light Positioning Systems: Fundamentals, Applications, and Challenges" (janv. 2024). Cette revue propose un panorama complet des systèmes VLP, couvrant les bases de la communication par lumière visible, les algorithmes de positionnement (triangulation, fingerprinting, hybridation), et les architectures réseau (placement LED, allocation de ressources). Elle identifie les applications comme la réalité virtuelle, la robotique et la navigation dans les bâtiments intelligents [19].
- "Li-Fi-enabled smart indoor navigation system with obstacle detection and voice assistance for visually impaired individuals" qui combine Li-Fi avec des capteurs à ultrasons pour éviter les obstacles, avec l'utilisation Interface vocale destinée aux personnes malvoyantes. L'étude a abouti à un rapport d'erreur < 30 cm, avec positionnement en temps réel [20].
- "Refining Wi-Fi Based Indoor Localization with Li-Fi Assisted Model Calibration in Smart Buildings". Bien qu'un peu ancien (2016), ce travail explore l'idée de calibrer un modèle de localisation Wi-Fi grâce à des signaux Li-Fi pour améliorer la précision. Les résultats expérimentaux montrent des gains significatifs dans la navigation intérieure [21].

1.3.7. Ultrasons

Les ultrasons sont des ondes mécaniques dont la fréquence est supérieure à la limite d'audition humaine (> 20 kHz). En géolocalisation intérieure, ils sont utilisés pour mesurer des distances précises grâce au temps de propagation du signal entre un émetteur et un ou plusieurs récepteurs. Ces mesures permettent de calculer une position précise par des techniques de trilatération ou triangulation.

La technologie ultrasonore, bien que limitée en portée, offre une précision remarquable à faible coût. Elle est souvent utilisée dans des systèmes hybrides (ex. : Ultrasons + IMU ou Ultrasons + UWB) pour tirer parti des complémentarités entre portée et précision. En raison

de la lenteur du son et de la sensibilité au bruit, elle est surtout adaptée aux environnements calmes et structurés.

Parmi, les travaux récents utilisant La technologie ultrasonore en navigation intérieure, on trouve : " Simultaneous Calibration and Navigation (SCAN) of Multiple Ultrasonic Local Positioning Systems", Gualda, D., et autres (2019) proposent un algorithme SCAN pour calibrer en temps réel des balises ultrasonores non calibrées tout en naviguant. Cet algorithme à base de filtres de Kalman (EKF/UKF) fusionnés avec l'odométrie du robot en temps réel. Le résultat obtenu : meilleure précision et adaptativité sur de grandes zones intérieures [22].

1.4. Synthèse comparative des technologies de géolocalisation intérieure

La géolocalisation en environnement intérieur repose sur une grande variété de technologies sans fil et optiques, chacune ayant des avantages, des limites et des domaines d'application spécifiques. Le tableau ci-dessous propose une comparaison croisée des technologies abordées dans le chapitre.

Tableau.1. 1. Tableau comparatif des technologies de géolocalisation intérieure

Technologie	Précision typique	Portée	Coût matériel	Sensibilité aux interférences	Consommation	Infrastructur e nécessaire	Remarques
Wi-Fi (RSSI, Fingerprinting)	2 – 5 m	20 – 50 m	Faible	Moyenne	Moyenne	Oui (AP existants)	Très répandu, mais bruité
BLE (Beacons)	1 – 3 m	5 – 20 m	Faible à moyen	Moyenne à élevée	Faible	Oui (balises)	Très mobile, mais moins précis
ZigBee	1 – 3 m	10 – 100 m	Faible	Moyenne	Très faible	Oui	Intégré aux objets IoT
UWB (Ultra Wide Band)	< 30 cm	10 – 40 m	Élevé	Faible	Moyen	Oui	Haute précision, faible latence
RFID (passif)	10 – 100 cm	< 5 m	Très faible	Élevée	Aucune/passive	Oui (lecteurs/tags)	Idéal suivi d'objets
Li-Fi	~10 cm – 1 m	1 – 10 m (LOS)	Moyen à élevé	Très sensible (lumière)	Faible	Oui (LEDs + récepteurs)	Bonne précision, peu déployée
Ultrasons	1 – 10 cm	1 – 10 m	Faible	Élevée (réflexions/ bruit)	Faible	Oui (émetteurs + micros)	Très précis mais sensibles

Parmi les remarques complémentaires on peut mentionner :

- **Les technologies à ultrasons** sont parmi les plus précises, mais exigent une ligne de vue directe ou des mécanismes de filtrage (réflexions, bruit ambiant).
- **Le Wi-Fi**, très répandu, est facile à exploiter, mais souffre d'une faible précision si les techniques avancées de fingerprinting ou machine learning ne sont pas utilisées.
- **Le BLE** reste le bon compromis entre coût, facilité de déploiement, et performances modérées.
- **Les approches hybrides (Wi-Fi + UWB ou BLE + Ultrasons)** sont aujourd'hui très explorées dans les recherches récentes pour combiner précision, portée et faible coût.
- **Li-Fi et RFID**, bien que très prometteuses, nécessitent encore des déploiements spécialisés et sont sensibles à la géométrie de l'environnement.

Ce qui nous ramène à conclure que le choix d'une technologie dépend du contexte d'usage, du niveau de précision requis, du budget, ainsi que de la mobilité des utilisateurs ou objets à suivre. Une tendance actuelle forte dans la littérature est d'adopter des approches hybrides, combinant les points forts de plusieurs technologies afin d'améliorer la robustesse, la précision et l'adaptabilité du système de positionnement intérieur.

1.5. Wi-Fi comme technologie de géolocalisation

Le Wi-Fi (Wireless Fidelity) est l'une des technologies les plus largement utilisées pour la géolocalisation intérieure. Il s'appuie sur les points d'accès (Access Points – APs) déjà présents dans de nombreux bâtiments (universités, centres commerciaux, hôpitaux, etc.), ce qui en fait une solution économique et facilement déployable. La géolocalisation par Wi-Fi repose principalement sur l'analyse de la puissance du signal reçu (RSSI), parfois combinée à des techniques de fingerprinting ou d'apprentissage automatique.

1.5.1. Principes de fonctionnement

1) Basé sur le RSSI (Received Signal Strength Indicator)

- Chaque point d'accès Wi-Fi émet un signal dont la puissance diminue avec la distance.
- Le terminal mesure les RSSI de plusieurs APs connus.
- Une estimation de la position est obtenue via :
 - Triangulation / trilatération (Voir la partie "2.3.1" du chapitre 2)
 - Modèles de propagation du signal

2) Technique du Fingerprinting (Empreinte radio)

- Étape 1 : *Phase de calibration*
 - Construction d'une base de données ("radio map") associant chaque position intérieure à un vecteur de RSSI.
- Étape 2 : *Phase d'exploitation*
 - Le système compare les RSSI mesurés à ceux stockés dans la base et estime la position la plus proche (via KNN, Random Forest, etc.).

3) Techniques avancées

- Intégration de **réseaux de neurones** (MLP, LSTM) ou de **SVM** pour améliorer la précision.
- Approche **hybride** avec inertiel, Bluetooth ou UWB.

1.5.2. Avantages et limitations

Avec la technique du fingerprinting, les systèmes de positionnement basés sur le Wi-Fi atteignent généralement une précision de l'ordre de 2 à 5 mètres dans les environnements denses, tout en maintenant une faible consommation énergétique. L'un des atouts majeurs de cette technologie réside dans son faible coût de déploiement, qui explique sa popularité persistante dans les applications de géolocalisation intérieure.

En effet, il n'est pas rare que les bâtiments ciblés soient déjà équipés de points d'accès Wi-Fi, ce qui permet d'exploiter l'infrastructure existante sans nécessiter de nouveaux investissements matériels. Une fois la position de ces bornes connue, elles peuvent être facilement intégrées à l'algorithme de localisation, améliorant ainsi la précision du système.

Aujourd'hui encore, la localisation par Wi-Fi demeure un sujet actif de recherche, avec des avancées notables en termes de précision et de robustesse. À titre d'exemple, le système Chronos, développé par le MIT, parvient à atteindre une précision décimétrique à l'aide d'un seul point d'accès, en exploitant des techniques avancées de mesure de temps de vol du signal Wi-Fi [23].

1.6. Travaux récents et tendances

La géolocalisation en environnement intérieur a connu une évolution rapide au cours des dernières années, en raison de l'intégration de services intelligents, de la gestion des bâtiments, et de la mise en œuvre de nouvelles technologies. Les chercheurs et les professionnels de l'industrie se sont concentrés sur l'amélioration de la précision, la réduction des coûts d'installation et l'intégration de méthodes d'intelligence artificielle (IA) pour surmonter les blocus des systèmes traditionnels.

1.6.1. Amélioration de la précision et réduction des erreurs de positionnement

Des recherches récentes reposent sur les techniques de fusion de données dans le but d'améliorer la précision du positionnement. Parmi celles-ci, la combinaison de Wi-Fi, Bluetooth Low Energy (BLE), UWB (Ultra-Wideband) et de capteurs inertiels (IMU) a fait l'objet de nombreuses études. Ces approches hybrides permettent de compenser les faiblesses d'une technologie en s'appuyant sur les avantages d'une autre.

Exemples de recherches :

- **FUSION Wi-Fi et UWB** : Un projet mené par **NIST** (National Institute of Standards and Technology) a proposé un système de **fusion Wi-Fi et UWB**, combinant la portée du Wi-Fi et la précision de l'UWB pour réduire les

erreurs de positionnement en intérieur. Ce système hybride a permis de réduire les erreurs de positionnement de 50 % par rapport à l'utilisation exclusive de Wi-Fi [24]-[26].

- **Wi-Fi + IMU** : Des chercheurs ont travaillé sur le développement des systèmes de localisation en fusionnant les mesures de RSSI (Received Signal Strength Indicator) Wi-Fi avec les données des gyroscopes et accéléromètres des smartphones. Cela permet de créer un modèle inertiel qui, même en cas de faibles signaux Wi-Fi ou d'interruptions du réseau, peut assurer un suivi en temps réel avec une précision de moins de 1 mètre dans des environnements complexes [27]-[29].

1.6.2. Utilisation de l'intelligence artificielle (IA) et de l'apprentissage automatique

L'intelligence artificielle (IA) et les algorithmes d'apprentissage automatique (Machine learning) sont devenus l'un des piliers incontournables au cœur des travaux récents en géolocalisation. Ces méthodes permettent de prédire et corriger les erreurs de positionnement dues à des facteurs environnementaux variables (obstacles, interférences, mouvement des utilisateurs).

Exemples de recherches :

- **Modèles d'apprentissage profond (Deep Learning)** : Des études récentes ont montré l'efficacité des réseaux de neurones convolutifs (CNN) et des réseaux récurrents (RNN), en particulier LSTM (Long Short-Term Memory), pour prédire la position en fonction des signaux Wi-Fi mesurés sur de longues périodes et sous diverses conditions. Un exemple notoire est le système DeepLoc-WiFi, qui utilise un CNN-LSTM hybride pour modéliser les séries temporelles de RSSI dans des environnements dynamiques, offrant une précision de localisation de moins de 2 mètres dans des environnements industriels [30]-[32][35].

- **Apprentissage par renforcement** : Des travaux ont pris en charge l'utilisation de l'apprentissage par renforcement pour améliorer la géolocalisation. Par exemple, un algorithme de Q-learning a été appliqué pour optimiser l'interprétation des signaux Wi-Fi en temps réel, ce qui permet une meilleure estimation de la position dans des environnements de plus en plus variables [36]-[39].

1.6.3. Technologies émergentes et nouvelles approches

1) Li-Fi (Light Fidelity)

- Le Li-Fi, une technologie qui utilise des lumières visibles pour la transmission de données, est en pleine expansion comme alternative ou complément du Wi-Fi pour la géolocalisation intérieure. Li-Fi peut offrir des précisions de l'ordre du centimètre, car le signal lumineux peut être précisément dirigé. Cependant, son utilisation nécessite une ligne de vue directe entre les émetteurs (LED) et les récepteurs, limitant ainsi son adoption dans les environnements non contrôlés [40][41].

2) Ultrasons pour la géolocalisation

- L'utilisation des ultrasons pour la localisation en intérieur a également fait l'objet de recherches récentes. Ces systèmes, en se basant sur le temps de vol (ToF) ou la différence de temps d'arrivée (TDoA) des signaux ultrasonores, peuvent offrir une précision de l'ordre de quelques centimètres. Une étude réalisée en 2023 par l'Université de Californie à Berkeley a montré que l'intégration de l'ultrason avec le Wi-Fi et les capteurs inertiels permet de surmonter les limitations liées à la propagation des ondes radio dans les environnements saturés [42]-[44].

3) Systèmes basés sur la lumière infrarouge

- Les systèmes IR (InfraRouge) sont également explorés dans des environnements spécifiques comme les hôpitaux ou les musées. Ces technologies utilisent des LEDs infrarouges pour envoyer des signaux qui sont captés par des récepteurs spécifiques. L'avantage majeur est que, contrairement aux signaux radio (Wi-Fi, BLE), la lumière infrarouge est moins sujette aux interférences, offrant une précision accrue dans des environnements très denses [45]-[47].

1.7. Positionnement du projet

Le présent projet se positionne autour d'une solution de géolocalisation intérieure basée sur l'exploitation du signal Wi-Fi (RSSI – Received Signal Strength Indicator), combinée à des techniques de traitement avancé par apprentissage automatique. L'approche retenue vise à modéliser les variations du signal Wi-Fi dans un environnement structuré (immeuble à deux étages) à l'aide de plusieurs méthodes de prévision : **ARIMA, Random Forest et GRU (Gated Recurrent Unit)**. Les données sont collectées à l'aide de l'application *Wi-Fi SweetSpots* et proviennent de 22 points fixes répartis sur deux niveaux.

Ce choix se justifie par plusieurs facteurs :

- **Disponibilité généralisée** des réseaux Wi-Fi dans les bâtiments modernes, évitant des coûts d'installation supplémentaires ;
- **Compatibilité avec les smartphones standards**, sans besoin de capteurs additionnels ;
- **Possibilité d'extension** via la fusion avec d'autres capteurs (IMU, BLE ou ultrasons), pour une précision accrue ;
- **Flexibilité des modèles de traitement du signal**, qui permettent une amélioration continue des performances sans modification matérielle.
- En comparaison avec d'autres technologies :

- Le **BLE** (via les beacons) et **Zigbee** sont plus écoénergétiques, mais requièrent une infrastructure dédiée.
- Le **Li-Fi** et l'**infrarouge (IR)** offrent des précisions centimétriques, mais sont fortement limités par la nécessité d'une ligne de vue directe.
- Les **ultrasons** présentent une précision élevée, mais sont sensibles aux interférences acoustiques et à la configuration de l'environnement.
- Les **technologies hybrides** (Wi-Fi + IMU, Wi-Fi + UWB, etc.) sont prometteuses mais plus complexes à déployer.

Ainsi, ce projet se situe à l'intersection entre accessibilité pratique, coût maîtrisé et précision raisonnable, tout en laissant la porte ouverte à des évolutions vers des systèmes plus complexes. Il s'inscrit également dans les tendances de recherche actuelles, où les approches hybrides et les techniques de deep learning prennent une place croissante dans l'optimisation des performances des systèmes de positionnement intérieur.

1.8. Conclusion

L'état de l'art met en évidence la diversité des solutions proposées pour la géolocalisation intérieure, ainsi que les défis techniques liés à la variabilité des signaux et à la complexité des environnements. Le Wi-Fi constitue une base accessible et flexible pour les systèmes de positionnement intérieur, notamment grâce à sa large adoption. Cependant, la variabilité du signal et la nécessité de calibration rendent son usage optimal lorsqu'il est couplé à des méthodes d'apprentissage automatique ou à des technologies complémentaires.

Chapitre 2 : Techniques de Géolocalisation à base de Wi-Fi

2.1. Introduction

Le développement des bâtiments intelligents, des services contextuels, et des systèmes de navigation pour les lieux clos tels que les centres commerciaux, les aéroports ou les hôpitaux, ont rendu le domaine de La géolocalisation en environnement intérieur un domaine de recherche crucial, Parmi les nombreuses technique et technologies proposées, le Wi-Fi s'impose comme l'une des plus utilisées, notamment en raison de sa large disponibilité, de son faible coût d'implémentation et de sa compatibilité avec les équipements mobiles existants.

Les réseaux Wi-Fi peuvent produire une solution de rechange fiable afin d'estimer ou prédire la position d'un utilisateur ou d'un objet. Le Wi-Fi exploite des points d'accès (AP) déjà présents dans l'environnement, permettant ainsi une géolocalisation sans nécessiter de déploiement d'infrastructure dédiée.

Différentes approches ont été développées pour tirer parti des signaux Wi-Fi à des fins de localisation : méthodes basées sur la puissance du signal reçu (RSSI), l'angle d'arrivée (AoA), le temps de vol (ToF), ou encore les informations de l'état du canal (CSI). Ces techniques peuvent être combinées avec des modèles statistiques, des algorithmes de machine learning ou encore des réseaux de neurones profonds pour améliorer la précision et la robustesse du positionnement.

Dans ce chapitre, nous présentons les principes fondamentaux de la localisation Wi-Fi, les principales méthodes utilisées, ainsi que les améliorations récentes apportées par les techniques d'intelligence artificielle.

2.2. Principes physiques du Wi-Fi pour la géolocalisation

La géolocalisation à base de Wi-Fi repose sur les propriétés physiques du signal électromagnétique émis par les points d'accès (AP – *Access Points*). Ces signaux, bien que conçus à l'origine pour la communication sans fil, présentent des caractéristiques mesurables qui peuvent être exploitées pour estimer la position d'un terminal mobile. Parmi les paramètres les plus utilisés figurent la puissance du signal reçu (RSSI), le temps de vol (ToF), l'angle d'arrivée (AoA), ainsi que les informations d'état du canal (CSI).

2.2.1. Technique basée sur le RSS (Received Signal Strength)

La localisation basée sur le RSS repose généralement sur des techniques de latération ou trilatération, où l'on utilise l'intensité du signal reçu pour estimer la distance entre l'appareil utilisateur et plusieurs points d'accès (ou points de référence). Pour obtenir une position fiable, il est nécessaire de mesurer ces distances à partir d'au moins trois points de référence. Ensuite, des principes géométriques ou trigonométriques sont appliqués afin de déterminer la position absolue de l'utilisateur dans l'espace. Ce processus est illustré à la **Fig 2. 1**, où la position de l'appareil est calculée à l'intersection des cercles correspondant aux distances estimées depuis les différents points d'accès [3].




Fig 2. 1. Technologie de propagation RSS-radio.

La puissance RSS est calculée à l'aide de la formule suivante :

$$p_i(d) = p_0 - 10\gamma \log_{10}(d) + S \dots \dots \dots (2.1)$$

Où :

- $p_i(d)$ en (dbm) : est la puissance du signal reçue à une distance d de l'émetteur au récepteur,
- d en (m) : distance entre deux nœuds, entre l'émetteur au récepteur.
- p_0 : est la puissance reçue à une distance de référence de 1m.
- Le paramètre γ est connu sous le nom d'exposant de perte de trajet, qui dans les environnements intérieurs prend généralement des valeurs comprises entre 2 et 6.
- S en (dB) : représente les variations de décoloration à grande échelle (c'est-à-dire l'ombrage). Il est courant de modéliser S comme une variable aléatoire Gaussienne avec une moyenne nulle et un écart type σ_S .

Cette méthode, bien qu'imparfaite, est la base de nombreuses techniques de trilatération ou de fingerprinting. Elle est simple à implémenter, mais sensible aux interférences, aux obstacles et aux phénomènes de multi-trajet.

2.2.2. Angle d'arrivée (AOA)

La méthode de localisation par Angle d'Arrivée (AOA) consiste à déterminer la direction d'origine d'un signal reçu en mesurant l'angle sous lequel ce signal atteint le récepteur. Cette estimation angulaire, également appelée Direction Finding (DF), s'effectue à l'aide d'antennes directionnelles ou de réseaux d'antennes capables de détecter les variations angulaires. Pour ce faire, la station de base (BS) ou la balise utilisée dans un système AOA est généralement équipée d'un réseau d'antennes directionnelles, dont chaque élément peut capter le signal en provenance de différentes directions avec une grande précision [48].

La localisation de la cible repose alors sur l'intersection de plusieurs lignes de direction angulaire, chacune partant d'une station de référence vers la cible mobile. Comme illustré à la **Fig 2. 2**, il suffit d'au moins deux stations de base placées en des points de référence connus (**A et B**), et de mesurer les deux angles d'arrivée (θ_1, θ_2) pour estimer la position **2D** de la cible P [49]-[50].




Fig 2. 2. Technique AOA avec trois mesures angulaires

La définition de la position du smartphone pour les coordonnées 2D est exprimée dans l'équation (2.2) :

$$(x_i - x_{sp})\sin(\theta_i) = (y_i - y_{sp})\cos(\theta_i) \dots \dots \dots (2.2)$$

Où x_i et y_i sont des valeurs de coordonnées **XY** des positions **BS / WAP**, θ_i est l'AOA pour les signaux **WAP** reçus et x_{sp} et y_{sp} sont des valeurs de coordonnées **XY** de la position du smartphone.

2.2.3. Technique basée sur le temps

Les techniques de géolocalisation basées sur la mesure du temps de propagation d'un signal — également appelé temps de vol (Time of Flight, TOF) permettent d'estimer les pseudo-distances entre un smartphone et plusieurs stations de base (BS) ou points d'accès Wi-Fi (WAP). Parmi ces approches, les plus courantes sont le Time of Arrival (TOA), le Round Trip Time (RTT), et le Time Difference of Arrival (TDOA) [3].

En particulier, la méthode TDOA (Différence de Temps d'Arrivée) détermine la position de l'utilisateur en analysant les différences de temps d'arrivée du signal reçues par différentes paires de stations. Ces différences sont ensuite utilisées pour résoudre un système d'équations hyperboliques, comme illustré par l'équation (2.3). Cette approche permet d'estimer la localisation sans nécessiter de synchronisation parfaite entre l'émetteur (le smartphone) et les récepteurs (BS/WAPs), ce qui en fait une solution robuste dans les environnements intérieurs complexes.

$$\begin{aligned}\Delta t_{12} &= t_1 - t_2 \\ \Delta t_{13} &= t_1 - t_3 \\ \Delta t_{23} &= t_2 - t_3 \dots \dots \dots (2.3) \\ \Delta p_{ij} &= \Delta t_{ij} * c\end{aligned}$$

Où t_1 est le temps mesuré des signaux reçus de **BSs/WAPs**, Δt_{ij} est la différence des deux signaux reçus de **BSs/WAPs**, Δp_{ij} est la différence estimée des pseudo-portés et c la vitesse de la lumière.

1. **L'instant d'arrivée (TOA) :** Le signal électromagnétique se propage à une vitesse constante et connue (proche de celle de la lumière). Les méthodes TOA reposent sur l'estimation du temps de propagation entre l'émetteur et le récepteur. Ce délai est généralement obtenu par corrélation croisée entre le signal émis et le signal reçu. Le pic principal de cette corrélation correspond à l'arrivée du signal en ligne de visée directe (LOS – Line of Sight), et permet d'estimer avec précision le temps de vol, donc la distance entre les deux appareils.

Comme illustré à la **Fig 2. 3**, chaque mesure de TOA permet de déterminer une distance entre un capteur et la cible, définissant un cercle centré sur le capteur. L'intersection de plusieurs cercles issus de capteurs distincts permet de localiser la cible. Pour obtenir une position unique en deux dimensions, il est nécessaire de disposer d'au moins trois capteurs, chacun fournissant une distance indépendante. Ce principe constitue la base de la trilatération temporelle utilisée dans de nombreux systèmes de positionnement intérieur.




Fig 2. 3. TOA à trois positions

2. **Différence des instants d'arrivées (TDOA) :** La différence est une variante de la méthode TOA, qui présente l'avantage de ne nécessiter la synchronisation que du côté des récepteurs fixes (stations de base). Elle repose sur un réseau de récepteurs stationnaires munis d'horloges synchronisées, qui collaborent pour déterminer la position de la source émettrice du signal [51]. Contrairement à TOA, où le temps absolu d'arrivée du signal est requis, TDOA mesure les différences de temps d'arrivée d'un même signal entre plusieurs récepteurs. Ces différences traduisent des écarts de distances relatives entre l'émetteur inconnu et les stations fixes. En exploitant ces écarts, le système déduit la position de la source à l'aide d'un ensemble d'équations hyperboliques, sans nécessiter que le dispositif mobile soit lui-même synchronisé avec les stations (Fig 2. 4).




Fig 2. 4. Localisation et détection de proximité basées sur TDOA.

3. Temps d'aller-retour du signal (RTOF) : RTOF mesure le temps de propagation du signal aller-retour (émetteur-récepteur) pour estimer la distance entre T_x et R_x . Pour RTOF, la condition de synchronisation d'horloge n'est pas aussi stricte que les exigences TOA, mais leurs mécanismes de mesure de distance sont les mêmes. TOA et RTOF ont des mécanismes de télémétrie similaires. Après avoir reçu le signal de l'émetteur, le récepteur répond à l'émetteur, puis l'émetteur calcule le total aller-retour TOA. La méthode Round-Trip Time of Flight (RTOF), également appelée Round-Trip Time (RTT), mesure le temps de propagation aller-retour d'un signal entre un émetteur (T_x) et un récepteur (R_x) afin d'estimer la distance qui les sépare [3]. Contrairement à la technique TOA, RTOF ne requiert pas une synchronisation stricte des horloges entre les deux dispositifs, car le même appareil (souvent le smartphone ou l'émetteur) gère l'envoi et la réception du signal. Le processus fonctionne comme suit : après réception du signal par le récepteur, ce dernier émet une réponse vers l'émetteur. Celui-ci calcule alors le temps total de l'échange aller-retour, puis en déduit la distance, en supposant une vitesse de propagation constante. Ainsi, TOA et RTOF partagent un mécanisme de télémétrie similaire, mais RTOF présente une meilleure praticité en raison de sa moindre exigence en matière de synchronisation temporelle.




Fig 2. 5. RTOF pour les déterminations de la géolocalisation d'un smartphone.

2.2.4. Technique Map-Matching

La technique MM (Mapping par apprentissage machine) repose sur les principes des algorithmes d'apprentissage automatique. Elle consiste à associer une carte préexistante de l'environnement à des observations de géolocalisation mesurées par le smartphone, afin d'estimer avec précision la position réelle de l'utilisateur dans un espace **2D ou 3D**.

Cette méthode peut être utilisée seule ou intégrée à d'autres approches telles que les techniques basées sur le temps (TOA, TDOA), sur la puissance du signal reçu (RSS), ou encore sur le Dead Reckoning (DR) [52]. Son principal avantage réside dans sa capacité à améliorer significativement la précision des systèmes de localisation, en exploitant des modèles prédictifs entraînés sur des données empiriques.

2.2.5. CSI (Channel State Information)

Les informations d'état du canal décrivent le comportement du signal entre chaque paire antenne émetteur-récepteur (amplitude, phase, écho). Contrairement au RSSI qui donne une seule valeur moyenne, le CSI fournit un vecteur complexe représentant le canal sur différentes sous-porteuses (OFDM). Cette granularité permet une analyse plus fine, en particulier pour détecter des caractéristiques du milieu comme les objets en mouvement ou les murs.

Le CSI est très prometteur pour les applications avancées de localisation, notamment en combinaison avec les techniques d'intelligence artificielle (CNN, LSTM). Il offre des possibilités de localisation au décimètre près, mais nécessite un accès bas niveau aux couches physiques de la carte Wi-Fi, ce qui peut être contraignant selon les appareils utilisés.

2.2.6. Propriétés radio des environnements intérieurs

Les environnements intérieurs posent des défis uniques :

- **Multipath** : les signaux se réfléchissent sur les murs, les sols, les meubles.
- **Fading** : les interférences constructives ou destructives altèrent le RSSI.

- **Non-linéarité** : les distances ne sont pas directement proportionnelles aux mesures.
- **Variabilité temporelle** : les mouvements d'objets ou de personnes affectent les signaux.

Ces phénomènes justifient l'usage de techniques avancées (modèles d'apprentissage, filtrage de Kalman, etc.) pour corriger ou compenser les incertitudes

2.3. Méthodes de géolocalisation Wi-Fi

La géolocalisation à base de Wi-Fi peut être mise en œuvre selon différentes méthodes, classées en deux grandes familles : les méthodes basées sur un modèle mathématique explicite (ex. trilatération) et les méthodes empiriques ou fingerprinting, souvent assistées par des algorithmes d'apprentissage automatique. Cette section présente ces approches, leurs principes, avantages et limites.

2.3.1. Trilatération (ou triangulation de distance)

Cette méthode repose sur l'estimation de la distance entre le terminal mobile et au moins trois points d'accès Wi-Fi. À partir du RSSI ou du ToF, la distance d_{dd} entre chaque point d'accès est estimée, puis utilisée dans un système d'équations pour calculer les coordonnées de l'utilisateur.

Les avantages de cette méthode :

- Simple et rapide à calculer.
- Ne nécessite pas de phase d'apprentissage.

Ses limites :

- Très sensible au bruit RSSI.
- Peu robuste dans les environnements à forte interférence ou en présence de multipath.

2.3.2. Triangulation angulaire (AoA)

Cette méthode exploite la direction du signal reçu par des antennes multiples pour estimer la position de la source. Elle est plus précise que la trilatération dans certains cas, mais nécessite un matériel plus complexe.

2.3.3. Fingerprinting (empreinte de signal)

Le terme "fingerprinting" provient du mot anglais signifiant "empreinte digitale", en référence à l'unicité de chaque configuration de signal captée à un emplacement donné. Cette technique repose sur l'établissement d'une base de données contenant un ensemble de caractéristiques spécifiques (généralement des valeurs **RSS ou RF**) associées à divers points de l'environnement cible.

Chaque empreinte numérique représente ainsi un profil unique du signal reçu (par exemple, les intensités de signaux Wi-Fi issues de différents points d'accès) à un emplacement précis. En phase d'exploitation (ou de localisation), l'empreinte actuelle mesurée est comparée aux empreintes enregistrées dans la base de données afin de déterminer l'emplacement le plus probable.

Les algorithmes de fingerprinting sont généralement classés en deux grandes catégories :

- Les **méthodes déterministes**, qui comparent directement les valeurs mesurées avec celles stockées en utilisant des métriques de distance (ex. : k-NN).
- Les **méthodes probabilistes**, qui modélisent la distribution statistique des signaux et estiment la position la plus probable selon un cadre bayésien ou autre.

Cette approche est largement utilisée dans les systèmes de géolocalisation en intérieur en raison de sa bonne précision et de sa compatibilité avec les infrastructures Wi-Fi existantes [53][54].

La méthode de fingerprinting est aujourd'hui la plus répandue dans les systèmes de géolocalisation Wi-Fi. Elle consiste à construire une base de données de signatures de signaux

(empreintes), associées à des positions connues, puis à comparer en temps réel la mesure du RSSI avec cette base pour estimer la position.

Elle comporte deux phases :

1. **Phase d'apprentissage (offline)** : on collecte les RSSI dans différentes zones de l'espace, en les associant à leurs coordonnées.
2. **Phase d'estimation (online)** : la signature RSSI mesurée est comparée à la base pour trouver la position la plus probable (ex. par KNN, SVM, Random Forest, etc.).

Les avantages de cette méthode :

- Haute précision, surtout dans des environnements denses.
- S'adapte à la complexité du milieu sans modélisation physique.

Inconvénients :

- Nécessite une collecte de données longue.
- Sensible aux changements dans l'environnement (meubles, personnes...).

2.3.4. Méthodes hybrides (Wi-Fi + capteurs)

Pour améliorer la précision ou compenser la dégradation des signaux, certaines approches combinent le Wi-Fi avec d'autres capteurs du smartphone [3] :

- **IMU (accéléromètre, gyroscope, magnétomètre)** : pour le suivi inertiel.
- **Bluetooth Low Energy (BLE)** ou **UWB** : pour des mesures plus précises en distance.
- **Filtres (Kalman, particulaire)** : pour lisser les mesures dans le temps.

2.3.5. Approches basées sur l'intelligence artificielle

L'émergence du **machine learning** et du **deep learning** a permis des avancées notables dans la localisation Wi-Fi :

- **KNN, SVM, Random Forest** : pour la correspondance de fingerprint.
- **CNN et LSTM** : pour modéliser des séries temporelles de RSSI.
- **Autoencoders, GANs** : pour générer ou compléter des bases d'empreintes.

Ces approches peuvent atteindre une précision inférieure à 2 mètres en milieu réel, voire décimétrique avec des données riches (CSI).

2.4. Conclusion

Ce chapitre à présenter les principales techniques de géolocalisation en environnement intérieur utilisant le Wi-Fi. Nous avons d'abord exploré les méthodes fondées sur la mesure du signal reçu (RSS), en particulier la technique du fingerprinting, qui reste aujourd'hui l'une des plus efficace en raison de sa simplicité de mise en œuvre et de sa compatibilité avec les infrastructures Wi-Fi existantes.

Nous avons également étudié les approches basées sur les **temps de propagation** (TOA, TDOA, RTT), les **angles d'arrivée (AOA)**, ainsi que les techniques de **fusion de données**, intégrant des capteurs inertiels (IMU) pour compenser les limites du signal dans des environnements complexes.

En résumé, la géolocalisation Wi-Fi constitue un domaine de recherche en plein essor, bénéficiant à la fois de l'avantage des réseaux sans fil, de la croissance des capacités de traitement embarquées, et des progressions en intelligence artificielle.

Chapitre 3 : Implémentation et Résultats expérimentaux

3.1. Cadre expérimental

Dans le but d'évaluer les performances des méthodes de géolocalisation basées sur les signaux Wi-Fi, une campagne expérimentale de collecte de données a été réalisée dans un environnement intérieur structuré. L'objectif est de tester et comparer trois approches de modélisation – **ARIMA**, **Random Forest** et **GRU** (expliquées en détail dans partie "3.3" du chapitre 3) – pour prédire la position d'un utilisateur en se basant sur l'intensité du signal reçu (RSSI) mesuré en différents points du bâtiment.

3.1.1. Description de l'environnement de test

L'environnement choisi est un **immeuble à deux étages**, chaque étage étant composé de **six chambres de dimensions similaires**. Ces pièces sont desservies par un couloir central, et présentent une variabilité architecturale modérée (portes fermées, présence de meubles, cloisons standards en béton ou placoplâtre). Le choix de cet environnement s'aligne avec les situations réelles où une localisation indoor est critique : bâtiments administratifs, hôpitaux, écoles, etc.

3.1.2. Équipement utilisé

La collecte des données RSSI a été réalisée à l'aide de l'application mobile **Wi-Fi SweetSpots**, installée sur un smartphone Android. Cette application enregistre l'intensité du signal Wi-Fi reçu (RSSI) au fil des déplacements de l'utilisateur dans l'environnement (**Fig 3. 1**).




Fig 3. 1. Application "Wi-Fi SweetSpots"

Le réseau sans fil utilisé est émis par un **modem-routeur D-Link DSL-224 N300**, compatible ADSL2+/VDSL2, et offrant un signal stable en 2.4 GHz. Aucun répéteur ou point d'accès secondaire n'a été ajouté afin de simuler un environnement minimaliste et réaliste pour un usage personnel ou professionnel (**Fig 3. 2**).



Fig 3. 2. Modem-routeur D-Link DSL-224 N300

3.1.3. Protocole de collecte des données

Le processus de collecte suit un protocole rigoureux :

- Les données sont collectées à des **points fixes réguliers** (tous les 50 cm environ), marqués au sol.
- Pour chaque point, nous avons réalisés des mesures à des intervalles de 2h 50m, durant la période aller du 07/03/2025 au 16/05/2025.
- La **position réelle** (coordonnées x, y) de chaque point est préalablement mesurée et associée manuellement aux enregistrements RSSI.

3.1.4. Objectifs de l'analyse

Les données collectées sont utilisées pour :

- Prédire les positions x et y à partir des valeurs RSSI en entrée.
- Évaluer la précision spatiale de chaque modèle (ARIMA, Random Forest, GRU).
- Comparer la robustesse des approches face aux variations environnementales (mobilier, interférences, etc.).

3.2. Prétraitement des données

Le bon fonctionnement des algorithmes d'apprentissage statistique et profond dépend fortement de la qualité des données fournies en entrée. Dans le cadre de cette étude, les données brutes issues de l'application **Wi-Fi SweetSpots**, restructurées et normalisées afin de garantir une modélisation fiable et performante.

3.2.1. Structure des données collectées

Chaque session de collecte produit un fichier contenant :

- Un identifiant temporel (timestamp)
- Les valeurs **RSSI** (en dBm) mesurées à différents instants
- Les identifiants des points d'accès Wi-Fi (SSID/BSSID)
- Le cas échéant, les coordonnées (x, y) associées au point de mesure

Cependant, la structure brute présente des données hétérogènes : certains points contiennent des mesures incomplètes, d'autres sont affectés par des fluctuations extrêmes du signal dues à des interférences temporaires ou des erreurs humaines lors du déplacement.

3.2.2. Alignement des mesures et des coordonnées

Une étape clé consiste à **lier chaque enregistrement RSSI à ses coordonnées (x, y) précises**. Cette correspondance est faite manuellement, ou semi-automatiquement par interpolation selon les repères marqués lors de la collecte. Chaque ligne du jeu de données final contient alors :

```
csharp
CopierModifier
[RSSI_AP1, RSSI_AP2, ..., RSSI_APn, x, y]
```

Les points d'accès non détectés à un instant donné sont marqués comme absents (valeurs manquantes), puis **remplis avec une valeur par défaut** (souvent -100 dBm), ou via **imputation statistique**.

3.2.3. Normalisation des données

Les algorithmes comme **GRU** nécessitent une mise à l'échelle des données. Ainsi :

- Les valeurs RSSI ont été **normalisées** entre 0 et 1 (Min-Max Scaling)
- Les coordonnées x et y ont également été normalisées si nécessaires, pour une convergence plus rapide durant l'entraînement

3.2.4. Découpage des données

Enfin, les données ont été divisées en trois ensembles :

- Ensemble d'entraînement : 70 %
- Ensemble de validation : 15 %
- Ensemble de test : 15 %

Ce découpage assure une évaluation rigoureuse des modèles sur des données inédites et permet d'éviter le surapprentissage.

3.3. Implémentation des modèles ARIMA, Random Forest et GRU

Pour modéliser et prédire la position d'un utilisateur à partir des données RSSI collectées, trois méthodes ont été sélectionnées et comparées : **ARIMA**, **Random Forest** et **GRU**. Chacune représente une approche différente (modèle statistique, apprentissage automatique, apprentissage profond), permettant ainsi une évaluation comparative sur la base de critères de précision, de robustesse et de complexité de mise en œuvre.

3.3.1. Modèle ARIMA (AutoRegressive Integrated Moving Average)

Principe : Le modèle **ARIMA(p,d,q)** est couramment utilisé pour prédire les valeurs futures d'une série temporelle en s'appuyant sur ses observations passées. Il combine trois éléments : l'auto-régression (**AR**), la moyenne mobile (**MA**) et la différenciation (**Integrated**) pour rendre la série stationnaire (Fig 3. 3) (pour plus de détail voir [55]). Concrètement :

- **p** représente le nombre de retards (lags) de la partie auto-régressive,
- **d** le nombre de différenciations nécessaires pour atteindre la stationnarité,
- **q** le nombre de termes de la moyenne mobile.

La **stationnarité** est une condition préalable essentielle : ARIMA ne peut être utilisé efficacement que si la série temporelle n'est ni un bruit blanc ni sujette à une saisonnalité marquée.

Dans le modèle ARIMA, la valeur future est une **combinaison linéaire** :

- Des valeurs passées (AR),
- Des erreurs de prédiction passées (MA),
- et d'un bruit aléatoire.

L'équation générale du modèle est :

$$Y_t = \alpha + \sum(\beta_i \times Y_{t-i}) + \sum(\varphi_i \times \varepsilon_{t-i}) + \varepsilon_t \dots \dots \dots (3.1)$$

où chaque terme décrit respectivement la constante, l'effet de mémoire (*AR*), la correction des erreurs passées (*MA*) et l'incertitude résiduelle (ε_t).

Les étapes de mise en œuvre sont les suivantes :

- Tester la stationnarité de la série ;
- Appliquer des différenciations si nécessaire ;
- Identifier les meilleurs paramètres (p, d, q) à l'aide de critères comme AIC ou BIC ;
- Construire le modèle ARIMA ;
- Évaluer sa précision sur des données de test.

1) Application :

- Chaque signal RSSI reçu est traité comme une série temporelle.
- Le modèle prédit la **valeur future de RSSI** à partir de laquelle la position estimée est recalculée (via un modèle géométrique ou une carte d'empreintes).
- ARIMA est plus adapté à des séquences linéaires, et moins efficace dans des environnements dynamiques avec de nombreuses perturbations.




Fig 3. 3. Architecture fonctionnelle d'un modèle ARIMA

3.3.2. Modèle Random Forest

1) **Principe** : Random Forest est un algorithme d'**apprentissage supervisé** basé sur un ensemble d'arbres de décision. Il est particulièrement efficace pour traiter des jeux de données avec plusieurs variables explicatives, même bruitées ou incomplètes (pour plus de détails voir [56]).

2) **Application** :

- Les RSSI mesurés de plusieurs points d'accès (AP1, AP2, ... APn) sont utilisés comme **variables d'entrée**.
- Les coordonnées **x** et **y** sont les **cibles à prédire**.
- Deux modèles Random Forest sont entraînés séparément : un pour **x**, un pour **y**.

3.3.3. Modèle GRU (Gated Recurrent Unit)

1) **Principe** : Les réseaux GRU sont une forme simplifiée de réseaux neuronaux récurrents (RNN) capables de modéliser des dépendances temporelles longues. Ils sont adaptés aux séries RSSI variant dans le temps, permettant une prédiction robuste dans des environnements dynamiques (**Fig 3. 4**) [57].

Il utilise deux portes principales :

- Porte de mise à jour (Update gate) : z_t .
- Porte de réinitialisation (Reset gate) : r_t .

Ces portes régulent ce que le neurone doit **oublier**, **retenir**, ou **mettre à jour** dans l'état caché " h_t " (Voir **Tableau.3. 1**).

2) **Application** :

- Entrée : séquence temporelle de RSSI mesurée sur un trajet donné
- Sortie : coordonnées (x, y) correspondantes à chaque pas de temps
- Nécessite des séries temporelles bien segmentées **et** normalisées




Fig 3. 4. Structure d'une unité récurrente à portes (GRU) de base

Tableau.3. 1. Signification des grandeurs du modèle GRU

Symbole	Signification	Rôle dans le GRU
h_{t-1}	État caché précédent à l'instant $t - 1$	Mémoire du réseau — il transporte les informations des pas précédents.
σ	Fonction sigmoïde logistique : $\sigma(x) = \frac{1}{1 + e^{-x}}$	Produit une sortie entre 0 et 1, utilisée pour les portes de contrôle.
z_t	Porte de mise à jour (update gate)	Détermine combien de l'ancien état h_{t-1} est conservé dans le nouvel état h_t .
r_t	Porte de réinitialisation (reset gate)	Contrôle combien de mémoire passée on prend en compte pour l'état temporaire.
$\hat{h}_t$	État candidat ou nouvelle mémoire proposée	État intermédiaire calculé avec r_t , utilisé pour générer h_t .
c_t	Parfois utilisé pour désigner le contexte ou état de cellule	Dans GRU classique, on ne l'utilise pas toujours (plutôt dans LSTM). Si présent, c'est un état global.
$\tanh$	Fonction tangente hyperbolique : $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Fonction d' activation non linéaire utilisée pour normaliser l'état intermédiaire $\hat{h}_t$.

3.3.4. Résumé des caractéristiques

Le **Tableau.3. 2** présente les caractéristiques essentielles des trois Modèles Adoptés (ARIMA ; Random Forest ; et GRU)

Tableau.3. 2. Caractéristiques des méthodes ARIMA ; Random Forest ; et GRU.

Méthode	Type	Avantages	Inconvénients
ARIMA	Statistique	Simple, rapide, peu de données	Linéaire, peu flexible
Random Forest	Apprentissage	Robuste, efficace sur données bruitées	Besoin de beaucoup de données étiquetées
GRU	Deep Learning	Modélise les séquences complexes	Nécessite des ressources et données importantes

3.4. Évaluation des performances des modèles

L'évaluation des performances est une étape cruciale pour comparer les capacités de prédiction des trois modèles étudiés : **ARIMA**, **Random Forest** et **GRU**. Elle se base sur des métriques quantitatives, mais aussi sur des considérations qualitatives liées à la robustesse, la latence, et l'adaptabilité aux environnements réels.

3.4.1. Métriques utilisées

Pour garantir une évaluation objective et comparable, la métrique suivante a été adopté :

- **RMSE (Root Mean Squared Error) :**

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \text{ pour } i = 1 \text{ à } n \dots \dots \dots (3.2)$$

Avec :

y_i : est la puissance du signal RSSI (en **dBm- décibels milliwatt**) reçue à une distance bien définie de l'émetteur au récepteur calculer à l'instant t_i .

$\hat{y}_i$: est l'estimation de y_i (en **dBm- décibels milliwatt**) reçue à une distance bien définie de l'émetteur au récepteur calculer à l'instant t_i .

$RMSE$: est mesurée donc en (**dBm**).

Met davantage l'accent sur les grandes erreurs.

3.4.2. Environnement de test

- **Infrastructure** : lieu d'expérimentation est une maison, constitué d'un rez-de-chaussée et 1 étages (6 chambres par étage), chaque pièce a été subdivisée en deux zones de mesure (**Fig 3. 5**).

Pour chaque chambre deux point de mesures fixes ont été sélectionnés. Au total, **22 points** de mesures fixes.




Fig 3. 5. Lieu d'expérimentation

- **Collecte des données** : application **Wi-Fi SweetSpots** sur smartphone, avec des enregistrements de RSSI dans chaque chambre et dans les couloirs.
- **Modem utilisé** : D-Link DSL-224 N300, fournissant un signal Wi-Fi stable dans tout l'immeuble.
- **Nombre total d'échantillons** : nous avons relevés 640 mesures.
- **Dispositifs** : smartphone Android équipé d'IMU (accéléromètre et gyroscope intégrés) pour tests avancés.

3.4.3. Collecte des données

Le jeu de données étudié contient des mesures de puissance du signal Wi-Fi (RSSI) recueillies à partir de différents emplacements à l'intérieur d'une maison. Chaque colonne, étiquetée *de P1 à P22*, correspond à un emplacement précis : *P1 à P10* représentent des pièces situées au **rez-de-chaussée**, tandis que *P11 à P22* concernent des zones situées au **premier étage**. Les valeurs enregistrées indiquent la **puissance du signal en dBm**, généralement comprise entre **−30 (signal très fort)** et **−90 (signal faible)**. Les horodatages montrent que les mesures ont été prises environ toutes les **2,5 heures**, pendant la période allant de mars 2025 à mai 2025 (**voir Tableau.3. 3**).

Ces lectures RSSI sont essentielles pour construire un **modèle de prédiction du comportement du signal**, ce qui peut contribuer au développement de **systèmes de géolocalisation ou de positionnement en intérieur**.

Tableau.3. 3. Exemple d'extrait représentatif des mesures RSSI collectées aux différents emplacements intérieurs

Date	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P13	P14	P15	P16	P17	P18	P19	P20	P21	P22
2025-03-07 00:00:00.000	-78	-75	-78	-87	-68	-69	-81	-83	-71	-70	-75	-65	-36	-49	-63	-62	-50	-34	-54	-52
2025-03-07 02:40:00.000	-77	-72	-78	-81	-62	-67	-83	-84	-74	-63	-73	-63	-37	-55	-68	-64	-53	-43	-53	-47
2025-03-07 05:19:59.990	-77	-75	-76	-82	-62	-67	-81	-85	-71	-63	-73	-63	-37	-55	-63	-63	-54	-32	-54	-53
2025-03-07 07:59:59.985	-77	-75	-76	-87	-62	-66	-83	-83	-71	-63	-75	-63	-37	-55	-63	-63	-52	-32	-54	-52
2025-03-07 10:39:59.980	-76	-74	-78	-81	-68	-67	-83	-83	-71	-63	-75	-65	-37	-55	-63	-63	-52	-32	-54	-52

3.5. Résultats

Des graphiques de comparaison entre les positions prédites et réelles ont été générés pour chaque modèle, sur les deux étages de l'immeuble. Voici un aperçu :

- **Étages testés** : rez-de-chaussée et 1er étage
- **Format** : nuage de points [x, y] avec trajectoires estimées vs trajectoires réelles
- **Logiciel utilisé** : Python.

La figure (**Fig 3. 6**) présente une comparaison des trois modèles prévisionnels ensemble dans un seul graphe, en utilisant la racine de l'erreur quadratique moyenne (RMSE) comme critère d'évaluation de leurs performances. Les modèles analysés sont : ARIMA, Random Forest, et GRU.

D'après les résultats observés, le modèle ARIMA affiche généralement les valeurs de RMSE les plus élevées, en particulier pour les capteurs **P19 et P20**. Cela suggère qu'ARIMA éprouve des difficultés à modéliser la complexité et la variabilité des signaux RSSI, surtout dans des environnements instables ou fortement bruités.




Fig 3. 6. Mesure de l'erreur RMSE (en dBm) d'emplacements (P1 : P22)

En revanche, le modèle **Random Forest** affiche de manière constante des **valeurs de RMSE plus faibles** sur la majorité des capteurs, ce qui témoigne de sa **capacité à gérer les non-linéarités** ainsi que les **comportements irréguliers** du signal Wi-Fi.

Par ailleurs, les modèles **GRU (Gated Recurrent Unit)** se démarquent particulièrement bien, notamment pour les capteurs situés à l'**étage supérieur** tels que **P19 et P22**. Grâce à leur capacité à **capturer les dépendances temporelles** et à modéliser avec précision les **variations à court terme**, ils surpassent à la fois ARIMA et Random Forest. La **mémoire interne** des GRU leur permet de retenir efficacement des séquences temporelles, ce qui en fait des modèles **particulièrement adaptés aux tâches de prédiction sensibles au temps**, comme la prévision du **signal RSSI en intérieur**.

Pour le **capteur P22**, le modèle **GRU** fournit une **prévision fluide et adaptable**, qui suit de très près le **signal réel**, en particulier lors des **pics soudains** et des **variations rapides**. Le modèle **Random Forest** parvient également à **reproduire les fluctuations** du signal de manière satisfaisante, bien que ses prédictions puissent parfois présenter des **oscillations plus marquées** (Fig 3. 7).

En revanche, le modèle **ARIMA** a tendance à générer des prédictions **trop lissées** ou **en décalage temporel**, ce qui le rend moins efficace pour **suivre les changements rapides** du signal RSSI.




Fig 3. 7. Prédiction du signal RSSI pour P22 à l'aide des modèles ARIMA, Random Forest et GRU.

En analysant les résultats pour le **capteur P21**, on observe que le modèle **Random Forest** parvient à **suivre avec précision la tendance du signal** et à **capturer ses principales fluctuations**. De son côté, le modèle **GRU** propose une courbe plus **lissée**, atténuant certaines variations abruptes. Encore une fois, le modèle **ARIMA** se montre **insuffisant pour représenter la dynamique réelle** de la série temporelle (Fig 3. 8).

Concernant le **capteur P20**, les modèles **GRU** et **Random Forest** offrent tous deux de **bonnes performances**, tandis qu'**ARIMA** reste en retrait, générant des **prédictions quasi constantes**, déconnectées des variations du signal (Fig 3. 9).

Pour ce qui est du **capteur P19**, qui présente une **forte volatilité** et des **changements fréquents**, le modèle **GRU** s'illustre particulièrement bien. Il parvient à **modéliser efficacement ces oscillations complexes**, ce qui confirme sa **supériorité dans la gestion de séries temporelles aux variations intenses** (Fig 3. 10).




Fig 3. 8. Prédiction du signal RSSI pour P21 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 9. Prédiction du signal RSSI pour P20 à l'aide des modèles ARIMA, Random Forest et GRU.

En observant les résultats du **capteur P18**, on constate que le modèle **Random Forest** a tendance à **surajuster (overfitting)** les données, ce qui se traduit par des prévisions **irrégulières et instables**. À l'inverse, le modèle **GRU** propose une **tendance plus stable**, bien

que légèrement **prudente** dans ses estimations. Quant à **ARIMA**, il échoue une fois de plus à **reproduire fidèlement la dynamique réelle du signal**.




Fig 3. 10. Prédiction du signal RSSI pour P19 à l’aide des modèles ARIMA, Random Forest et GRU.

Pour les capteurs **P17** et **P16**, où la **variabilité du signal est plus modérée**, le modèle **GRU** continue de bien performer, notamment pour **suivre les tendances à la hausse**, tandis que **Random Forest** s’avère efficace pour capter les **fluctuations à court terme**. **ARIMA**, en revanche, **reste à la traîne** en matière de précision.

D’un point de vue scientifique, les **signaux RSSI** en environnement intérieur sont fortement influencés par plusieurs facteurs : la **propagation par trajets multiples (multipath)**, la **perte de signal** due aux murs ou aux plafonds, ainsi que les **interférences générées par d’autres appareils**. Ces éléments engendrent un **comportement du signal à la fois non stationnaire et non linéaire**, ce qui rend les **modèles linéaires traditionnels comme ARIMA peu adaptés** à des prévisions précises.

De plus, les **capteurs situés à l’étage supérieur** (P11 à P22) présentent généralement une **variabilité plus élevée**, probablement en raison d’une **obstruction accrue du signal** et d’un **phénomène de réflexion** plus prononcé.




Fig 3. 11. Prédiction du signal RSSI pour P18 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 12. Prédiction du signal RSSI pour P17 à l'aide des modèles ARIMA, Random Forest et GRU.

En commençant par le **capteur P19**, situé au **premier étage**, on remarque que les **valeurs du signal varient considérablement**, ce qui met en évidence de **fortes dynamiques temporelles**. Le modèle **GRU** parvient à bien **suivre la tendance générale**, en particulier lors des **pics et creux** situés entre les indices temporels **40 et 80**. De son côté, **Random Forest** suit correctement les **principales fluctuations**, mais peine à gérer les **transitions brusques**. Quant à **ARIMA**, il ne parvient pas à **s'adapter à ces variations**, produisant des **prédictions excessivement lissées**, qui sont nettement insuffisantes dans les situations volatiles (**Fig 3. 10**).




Fig 3. 13. Prédiction du signal RSSI pour P16 à l'aide des modèles ARIMA, Random Forest et GRU.

En ce qui concerne le **capteur P18**, le signal est **particulièrement bruité**. Le modèle **Random Forest** tente de **suivre le rythme des changements rapides**, mais **surestime fréquemment certaines valeurs**, ce qui indique un **surapprentissage sur le bruit de court terme**. À l'inverse, le modèle **GRU** propose une prédiction plus **lissée**, qui capte bien la **tendance globale**, mais **au détriment de certains détails locaux**. Une fois de plus, **ARIMA montre ses limites**, en générant des sorties **quasiment constantes**, incapables de modéliser les irrégularités temporelles du signal (**Fig 3. 11**).

Ce cas met en lumière l'**importance d'utiliser des modèles dotés de mémoire temporelle**, tels que **GRU**, pour traiter les **signaux RSSI comportant des motifs bruités à haute fréquence** en environnement intérieur.

Le **capteur P17** présente des **tendances intéressantes**, marquées par des **pics** et des **creux significatifs**. Le modèle **GRU** parvient à **reproduire fidèlement les transitions** du signal réel, notamment autour des indices 60 et 120, où les variations sont les plus nettes (**Fig 3. 12**).

De son côté, le modèle **Random Forest** réussit globalement à **s'adapter aux changements du signal**, mais il montre certaines **difficultés à maintenir une cohérence temporelle**, ce qui peut entraîner des **prédictions irrégulières sur la durée**.

Quant au modèle **ARIMA**, il se révèle **trop rigide** face à la nature non linéaire de la série. Ses prévisions sont **quasiment plates**, ce qui **confirme ses limites dans la modélisation de signaux complexes** présentant des **variations non linéaires et dynamiques**.




Fig 3. 14. Prédiction du signal RSSI pour P15 à l’aide des modèles ARIMA, Random Forest et GRU.

En examinant les **capteurs P16 à P14**, les tendances observées précédemment se confirment.

Le **capteur P16** présente de **fortes fluctuations du signal**. Le modèle **Random Forest** réagit bien aux variations, mais ses prédictions sont parfois **bruitées**. À l’inverse, le modèle **GRU** propose des estimations **plus lisses**, qui permettent une lecture plus stable du comportement global (**Fig 3. 13**).

Pour le **capteur P15**, caractérisé par des **transitions rapides**, les deux modèles — **GRU** et **Random Forest** — parviennent à suivre les changements. Toutefois, **GRU** tend à générer des **trajectoires plus continues**, ce qui lui permet de mieux **équilibrer réactivité et capacité de généralisation** (**Fig 3. 14**).




Fig 3. 15. Prédiction du signal RSSI pour P14 à l'aide des modèles ARIMA, Random Forest et GRU.

Au niveau du **capteur P14**, **GRU** se distingue à nouveau en **reproduisant fidèlement la forme globale du signal**, malgré une **forte variabilité**. En revanche, **Random Forest** devient quelque peu **instable**, et **ARIMA** reste **trop figé**, incapable de suivre les dynamiques du signal (**Fig 3. 15**).

Avec le **capteur P13**, les modèles rencontrent des **difficultés importantes** dues à la présence de **composantes haute fréquence** et à des **variations de la ligne de base du signal**. Le modèle **Random Forest** présente des **mouvements brusques** qui suivent certains pics, mais **amplifient également le bruit**, ce qui nuit à la stabilité de la prédiction. En revanche, le modèle **GRU** offre des prédictions **plus lisses**, privilégiant une **approximation globale de la tendance**, et surpasse à nouveau **ARIMA**, qui continue à **sous-estimer la complexité du signal** (sous-apprentissage) (**Fig 3. 16**).

En passant au **capteur P10**, le schéma devient plus clair : les modèles **GRU** et **Random Forest** réussissent tous deux à **suivre fidèlement les creux bien structurés du signal réel**. À l'opposé, **ARIMA** affiche un **retard important** ou génère des **lignes quasi horizontales**, ne reflétant pas la variabilité réelle du signal (**Fig 3. 19**).




Fig 3. 16. Prédiction du signal RSSI pour P13 à l'aide des modèles ARIMA, Random Forest et GRU




Fig 3. 17. Prédiction du signal RSSI pour P12 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 18. Prédiction du signal RSSI pour P11 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 19. Prédiction du signal RSSI pour P10 à l'aide des modèles ARIMA, Random Forest et GRU.

Le **capteur P9** met en évidence un signal très **dynamique et irrégulier**. Les modèles **GRU** et **Random Forest** parviennent partiellement à suivre les variations : **Random Forest** affiche une certaine **réactivité**, mais au prix d'un **surapprentissage**, avec des sauts fréquents dans les prévisions. **GRU**, quant à lui, s'en sort mieux en **capturant les cycles et les changements de direction** sans réagir de manière excessive. Le modèle **ARIMA** reste quasiment plat, confirmant son inefficacité face à des données de cette complexité (**Fig 3. 20**).

Les capteurs **P8 à P6** confirment ces tendances. Au niveau de **P8**, **GRU** et **Random Forest** restent globalement **proches du signal réel**, mais avec des comportements distincts : **Random Forest** se montre plus **réactif**, tandis que **GRU** produit des **prévisions plus lissées** (**Fig 3. 21 : Fig 3. 23**).

Le **capteur P7** constitue un **cas difficile**, probablement en raison d'un **bruit important** ou d'un **signal très faible**. Tous les modèles rencontrent ici des **difficultés**. **GRU** propose une courbe stable, mais **trop simplifiée** (sous-apprentissage), tandis que **Random Forest** détecte certains **pics**, mais perd en **cohérence** globale. **ARIMA**, encore une fois, reste **décorrélé des motifs réels** du signal.

Enfin, le **capteur P6** présente des **variations modérées**. Dans ce contexte, **GRU offre globalement les meilleures performances**, avec une bonne capacité à suivre les tendances sans se laisser perturber par des irrégularités mineures.




Fig 3. 20. Prédiction du signal RSSI pour P9 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 21. Prédiction du signal RSSI pour P8 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 22. Prédiction du signal RSSI pour P7 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 23. Prédiction du signal RSSI pour P6 à l'aide des modèles ARIMA, Random Forest et GRU.

Enfin, les **capteurs P5 à P1**, situés au **rez-de-chaussée**, présentent globalement un **comportement du signal plus stable**. Le modèle **GRU** conserve ici un **avantage clair**, en produisant des prévisions qui **suivent fidèlement les tendances générales** tout en **ignorant les perturbations** de faible intensité. **Random Forest** reste **très réactif aux variations à court terme**, mais ses prédictions deviennent parfois **irrégulières**, en particulier lorsque le signal change de direction de manière abrupte.

Le modèle **ARIMA** obtient dans ce cas des **résultats légèrement meilleurs** que pour les capteurs de l'étage supérieur, mais **manque toujours de flexibilité** pour s'aligner avec le comportement réel du signal.

Par exemple, pour les capteurs **P2** et **P1**, le modèle **GRU** **parvient à reproduire efficacement la forme d'onde du signal réel**, tandis que **Random Forest** **tend à osciller de manière excessive**, et **ARIMA** reste **trop simpliste** pour refléter les variations observées.




Fig 3. 24. Prédiction du signal RSSI pour P5 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 25. Prédiction du signal RSSI pour P4 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 26. Prédiction du signal RSSI pour P3 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 27. Prédiction du signal RSSI pour P2 à l'aide des modèles ARIMA, Random Forest et GRU.




Fig 3. 28. Prédiction du signal RSSI pour P1 à l'aide des modèles ARIMA, Random Forest et GRU.

Le modèle **GRU (Gated Recurrent Unit)** se distingue clairement comme **la solution la plus performante pour la prédiction du signal RSSI en environnement intérieur**. Sa véritable force réside dans sa **capacité à reconnaître les motifs temporels** et à **s'adapter aux évolutions du signal**. Le modèle **Random Forest** offre également de bons résultats et constitue une **alternative intéressante**, notamment dans les contextes où les variations du signal sont **plus simples ou plus structurées**.

En revanche, le modèle **ARIMA** montre ses **limites dans ce domaine**, car il a du mal à suivre la **nature non linéaire et instable des signaux RSSI** en milieu intérieur.

D'un point de vue pratique, cette analyse suggère que pour des **applications de géolocalisation en temps réel** ou de **cartographie des signaux** en environnement intérieur, **le modèle GRU devrait être privilégié**. Il peut aussi être utilisé en **complémentarité avec Random Forest** dans une approche **hybride ou ensembliste**, afin d'**améliorer la fiabilité des prédictions**. Une telle combinaison pourrait fournir des **estimations de signal robustes et cohérentes**, indispensables pour des services de géolocalisation efficaces dans des **maisons intelligentes**, pour la **navigation robotique** ou encore pour le **suivi d'objets en intérieur**.

Globalement, **GRU offre les performances les plus stables et robustes**, quelle que soit la condition du signal : bruité, fortement variable ou comportant des tendances marquées. **Random Forest** se montre particulièrement **réactif face aux fluctuations**, mais il présente un **risque de surapprentissage** dans les environnements à forte variance. Enfin, **ARIMA reste systématiquement en retrait**, du fait de sa structure **linéaire et sans mémoire**, peu adaptée aux caractéristiques de la **propagation du signal Wi-Fi en intérieur**.

Ainsi, pour les systèmes de géolocalisation en intérieur basés sur la **prévision du RSSI**, **le modèle GRU constitue le choix le plus fiable**, en particulier lorsque **la précision et la stabilité** sont des critères essentiels.

3.6. Synthèse et Discussion

Cette étude s'est penchée sur l'évaluation comparative de trois modèles prévisionnels (**ARIMA, Random Forest et GRU**) appliqués aux données **RSSI (Received Signal Strength Indicator)** collectées dans **22 emplacements (P1 à P22)** répartis sur **deux étages** d'un immeuble. Chaque capteur représente un point précis où l'intensité du signal Wi-Fi a été mesurée au fil du temps. L'objectif est d'évaluer dans quelle mesure ces modèles peuvent **prédire les valeurs RSSI**, élément fondamental pour assurer une **géolocalisation intérieure précise**, indispensable dans les services contextuels, la domotique ou les systèmes de navigation en intérieur.

Les résultats mettent en évidence des **différences significatives** de performance selon les modèles et les contextes spatiaux. Le modèle **GRU** se distingue nettement, surpassant

régulièrement les autres, notamment dans des environnements **dynamiques et bruités**, comme ceux du **premier étage (P11 à P22)**. Dans ces zones, les obstacles, les effets multi-trajets et les interférences altèrent fortement la qualité du signal. Grâce à son **architecture récurrente**, intégrant une **mémoire temporelle** et une capacité de **traitement non linéaire**, le GRU capture efficacement les séquences temporelles des variations RSSI. Ses prédictions sont proches des valeurs réelles, en particulier lors de **baisses ou hausses rapides du signal**, ce qui en fait un excellent candidat pour les **applications exigeant précision et adaptabilité**.

Le modèle **Random Forest**, quant à lui, s'impose comme un **bon modèle de référence**. Il excelle dans les environnements où la variabilité du signal est modérée. Sa capacité à modéliser les **relations non linéaires sans avoir besoin de dépendances temporelles** lui permet de capter les tendances générales. Toutefois, il est sujet à un **surapprentissage** dans les contextes trop volatils, avec des **prédictions parfois instables** et des **valeurs de RMSE élevées** sur certains capteurs. Malgré cela, sa **simplicité**, son **interprétabilité** et ses **performances moyennes satisfaisantes** en font un candidat solide pour une **approche hybride ou ensembliste**.

En revanche, le modèle **ARIMA** présente des **limitations structurelles importantes**. Conçu pour des séries **linéaires et stationnaires**, il peine à modéliser la **complexité et le bruit** des signaux Wi-Fi intérieurs. Il génère souvent des prédictions **trop lissées ou plates**, négligeant les variations locales et globales du signal. Cela en fait le **modèle le moins adapté** à cette application, en particulier dans des contextes non stationnaires typiques des environnements intérieurs (mouvements humains, disposition des meubles, structure architecturale).

D'un point de vue **spatial**, les capteurs situés au **rez-de-chaussée (P1 à P10)** présentent une **variabilité plus faible**, ce qui se traduit par de **meilleures performances** pour tous les modèles, y compris ARIMA. À l'inverse, les capteurs du **premier étage (P11 à P22)** sont **plus affectés par les perturbations**, soulignant la **nécessité de modèles séquentiels avancés** comme GRU. La baisse de performance d'ARIMA dans ces zones accentue encore son **manque de robustesse en situation réelle**.

En conclusion, **la prévision des signaux RSSI en intérieur** constitue un **défi d'apprentissage complexe et non linéaire**, qui exige des modèles capables de **reconnaître les motifs temporels** et de **s'adapter aux changements contextuels**. Le **GRU**, en tant que réseau de neurones récurrent, répond parfaitement à ces exigences. Sa capacité à **mémoriser les informations pertinentes** et à **ignorer les perturbations** permet d'obtenir des **prédictions stables et précises**.

D'un point de vue **pratique**, les résultats suggèrent que les modèles basés sur GRU devraient constituer **la base des systèmes de géolocalisation intérieure utilisant le RSSI**. Le **Random Forest** peut jouer un rôle complémentaire dans une **architecture hybride**, en apportant plus de robustesse et une meilleure explicabilité. Bien qu'ARIMA soit utile dans d'autres contextes de prévision, il n'est **pas adapté seul à cette application**.

Pour résumer, l'utilisation du **GRU** dans les systèmes de géolocalisation intérieure offre des **avantages réels** en matière de **précision, fiabilité et souplesse**. Associée à un **prétraitement adéquat des données** et à des modèles hybrides potentiels, cette approche représente une **solution intelligente et évolutive** au défi de la **localisation en temps réel** basée sur les réseaux Wi-Fi largement disponibles.

3.7. Conclusion

Dans ce chapitre, nous avons exploré et comparé les performances de trois modèles de prévision — **ARIMA**, **Random Forest** et **GRU** — appliqués aux mesures de puissance du signal Wi-Fi (**RSSI**) collectées dans différents emplacements d'un immeuble à deux étages. Ces données, issues de l'application **Wi-Fi SweetSpots**, ont permis de simuler un scénario réaliste de **géolocalisation en environnement intérieur**, avec des conditions variées en termes de bruit, d'obstacles et de dynamique du signal.

L'analyse des résultats met en évidence les **limites des modèles traditionnels** comme **ARIMA**, qui échouent à capturer les fluctuations complexes et non stationnaires des signaux RSSI. Bien qu'il offre des performances acceptables dans les zones stables (rez-de-chaussée), ARIMA s'avère inadapté dans des environnements plus dynamiques, tels que les zones à l'étage où le signal est soumis à des interférences plus importantes.

Le modèle **Random Forest** a démontré une **capacité raisonnable à suivre les variations du signal**, grâce à sa nature non linéaire et sa robustesse vis-à-vis des données bruitées. Toutefois, il souffre parfois de **surapprentissage**, notamment dans les contextes à forte variabilité temporelle.

C'est finalement le modèle **GRU** (Gated Recurrent Unit) qui a montré la **meilleure performance globale**. Grâce à sa capacité à mémoriser les séquences temporelles, il s'adapte efficacement aux tendances, aux ruptures soudaines et aux motifs complexes. GRU constitue ainsi **la solution la plus fiable et stable** pour des systèmes de géolocalisation indoor reposant sur le RSSI.

En somme, les résultats obtenus dans ce chapitre permettent d'établir que :

- Le **GRU est le modèle le plus adapté** à la prévision du RSSI en environnement intérieur, en raison de sa précision et de sa capacité à gérer la complexité temporelle des données.
- Le **Random Forest** peut être utilisé comme **modèle complémentaire**, notamment dans des approches hybrides ou ensemblistes.
- Le modèle **ARIMA**, bien que pertinent dans d'autres contextes, **n'est pas recommandé** pour des applications de localisation basées sur des signaux Wi-Fi fluctuants.

Ces conclusions orientent naturellement vers l'implémentation de **systèmes de géolocalisation intelligents et robustes**, reposant sur l'apprentissage profond et la fusion de modèles, pour répondre aux défis posés par la navigation en intérieur, la domotique et le suivi d'actifs.

Conclusion et perspectives

Dans ce travail, Ce travail a porté sur la problématique de la **géolocalisation en environnement intérieur**, en s'appuyant principalement sur l'exploitation du **signal Wi-Fi (RSSI)**. Contrairement aux systèmes GPS inefficaces à l'intérieur des bâtiments, le Wi-Fi offre une alternative viable grâce à sa large disponibilité et son faible coût d'infrastructure.

Dans une première phase, un **état de l'art approfondi** a permis de comparer diverses technologies de géolocalisation indoor (Bluetooth, RFID, Zigbee, UWB, Li-Fi, Ultrasons...) en termes de précision, coût, consommation énergétique et faisabilité. Ce cadre a confirmé que le **Wi-Fi**, malgré certaines limitations, reste l'une des technologies les plus prometteuses pour les déploiements à grande échelle.

Dans un second temps, une **expérimentation sur site** a été menée à l'aide de l'application **Wi-Fi SweetSpots**, dans un bâtiment réel à deux étages. Des données RSSI ont été collectées dans 22 positions différentes, et trois modèles de prédiction ont été implémentés pour estimer les variations du signal :

- **ARIMA** : modèle linéaire classique,
- **Random Forest** : méthode d'ensemble basée sur des arbres de décision,
- **GRU (Gated Recurrent Unit)** : réseau neuronal profond spécialisé dans les séries temporelles.

Les résultats ont mis en lumière les **limites des approches traditionnelles** comme ARIMA, incapable de s'adapter aux fluctuations non linéaires et instables des signaux RSSI. À l'inverse, **le modèle GRU a montré une nette supériorité**, tant en précision qu'en stabilité, particulièrement dans les environnements complexes du premier étage. **Random Forest** s'est révélé un compromis intéressant, bien qu'il soit sensible au surapprentissage dans les zones très dynamiques.

1. Principales conclusions tirées de l'étude

- La **géolocalisation par Wi-Fi est réalisable avec une bonne précision**, notamment si elle est couplée à des algorithmes d'apprentissage performants.
- **Les modèles basés sur les réseaux neuronaux récurrents**, en particulier **GRU**, s'avèrent les plus pertinents pour modéliser les séries temporelles RSSI.
- Une **approche hybride** combinant GRU et Random Forest pourrait renforcer la robustesse dans les environnements variés et bruités.

2. Perspectives

Plusieurs pistes de recherche et d'amélioration peuvent être envisagées à la suite de ce travail :

- **Amélioration de la base de données :**

Enrichir la base de données RSSI en augmentant la fréquence des mesures, en intégrant plus d'étages ou de zones cibles, et en incluant des cas d'usage mobiles (utilisateur en déplacement).

- **Fusion multi-capteurs :**

Combiner les mesures Wi-Fi avec d'autres capteurs embarqués (accéléromètre, gyroscope, magnétomètre) pour créer des **modèles de géolocalisation inertielle (Wi-Fi + IMU)** encore plus robustes.

- **Déploiement en temps réel :**

Intégrer les modèles GRU dans une **application mobile ou système embarqué temps réel**, capable de fournir des coordonnées précises en déplacement.

- **Exploration d'autres modèles d'apprentissage profond :**

Étudier l'apport de **Transformers**, **LSTM bidirectionnels** ou **convolutions 1D** pour améliorer encore la prédiction du RSSI dans des environnements complexes.

- **Approche distribuée et edge computing :**

Implémenter les modèles de prédiction directement sur des équipements à faible consommation (Raspberry Pi, ESP32, smartphones) pour éviter une dépendance au cloud.

- **Applications pratiques :**

Étendre l'application aux domaines concrets comme la **navigation robotique**, la **logistique intérieure (tracking d'actifs)**, ou encore les **services contextuels dans les bâtiments intelligents**.

Bibliographies

- [1] Krieg, J. G. (2017). *Localisation indoor à l'aide des capteurs d'un smartphone* (Doctoral dissertation).
- [2] Navstar, G. P. S. (1993). GLONASS: global satellite navigation systems, Daly, P. *Electronics & Communication Engineering Journal*, 5(6), 349-357.
- [3] GHERIB, K. *GEOLOCALISATION DES PERSONNES EN ENVIRONNEMENT INDOOR VIA LA FUSION DES CAPTEURS DE SMARTPHONE* (Doctoral dissertation, UNIVERSITÉ KASDI MERBAH OUARGLA).
- [4] ELAGGOUNE, H., ZERROUKI, F. Z., & OUARGLI, L. *Towards Indoor Localization Guided by Machine Learning* (Doctoral dissertation, UNIVERSITY OF KASDI MERBAH OUARGLA).
- [5] Xiao, H., Zhang, H., Wang, Z., & Gulliver, T. A. (2017, August). An RSSI based DV-hop algorithm for wireless sensor networks. In *2017 IEEE Pacific Rim Conference on Communications, Computers and Signal Processing (PACRIM)* (pp. 1-6). IEEE.
- [6] Sun, M., Wang, Y., Xu, S., Qi, H., & Hu, X. (2020). Indoor positioning tightly coupled Wi-Fi FTM ranging and PDR based on the extended Kalman filter for smartphones. *IEEE Access*, 8, 49671-49684.
- [7] Simões, W. C., Machado, G. S., Sales, A., de Lucena, M. M., Jazdi, N., & de Lucena, V. F. (2020). A review of technologies and techniques for indoor navigation systems for the visually impaired. *Sensors*, 20(14), 3935.
- [8] Hafashimana, E. (2025). *Conception et mise en oeuvre d'un système de navigation intérieure économique utilisant des technologies open-source dans les bâtiments universitaires* (Doctoral dissertation, Université du Québec à Chicoutimi).
- [9] BALLESTEROS, M. (2002). Les technologies sans-fil. *EIVD, Juin*.
- [10] <https://www.linuxembedded.fr/2018/05/la-localisation-indoor-etat-de-l-art-technologique-12>
- [11] <https://www.minew.com/fr/short-range-wireless-connection-technology/>
- [12] Satan, A. (2018, May). Bluetooth-based indoor navigation mobile system. In *2018 19th international carpathian control conference (ICCC)* (pp. 332-337). IEEE.
- [13] Singh, A., Shreshthi, Y., Waghchoure, N., & Wakchaure, A. (2018, August). Indoor navigation system using bluetooth low energy beacons. In *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)* (pp. 1-5). IEEE.
- [14] Tiemann, J., Koring, L., & Wietfeld, C. (2018). ATLAS: TDOA-based UWB localization. *Microsoft Indoor Localization Competition-IPSN 2018*.
- [15] Olszewski, B., Fenton, S., Tworek, B., Liang, J., & Yelamarthi, K. (2013, May). RFID positioning robot: An indoor navigation system. In *IEEE International Conference on Electro-Information Technology, EIT 2013* (pp. 1-6). IEEE.
- [16] Zafari, F., Gkelias, A., & Leung, K. K. (2019). A survey of indoor localization systems and technologies. *IEEE Communications Surveys & Tutorials*, 21(3), 2568-2599.

- [17] Retscher, G., & Fu, Q. (2010, May). Continuous indoor navigation with RFID and INS. In *IEEE/ION position, location and navigation symposium* (pp. 102-112). IEEE.
- [18] Sharma, R. R., & Raunak, A. S. (2014). Li-Fi Technology. *International Journal of Computer Technology and Applications*, 5(1), 150-154.
- [19] Zhu, Z., Yang, Y., Chen, M., Guo, C., Cheng, J., & Cui, S. (2024). A survey on indoor visible light positioning systems: Fundamentals, applications, and challenges. *IEEE Communications Surveys & Tutorials*.
- [20] Sophia, N. A., Deepika, N., Vigneshwari, M., Lakshmi, P. S., Venitha, E., & Kalaivani, K. P. (2025). Li-Fi-enabled smart indoor navigation system with obstacle detection and voice assistance for visually impaired individuals. In *Challenges in Information, Communication and Computing Technology* (pp. 141-146). CRC Press.
- [21] Huang, Q., Zhang, Y., Ge, Z., & Lu, C. (2016). Refining Wi-Fi based indoor localization with Li-Fi assisted model calibration in smart buildings. *arXiv preprint arXiv:1602.07399*.
- [22] Gualda, D., Ureña, J., García, J. C., García, E., & Alcalá, J. (2019). Simultaneous calibration and navigation (SCAN) of multiple ultrasonic local positioning systems. *Information Fusion*, 45, 53-65.
- [23] Vasisht, D., Kumar, S., & Katabi, D. (2016). {Decimeter-Level} localization with a single {WiFi} access point. In *13th USENIX symposium on networked systems design and implementation (NSDI 16)* (pp. 165-178).
- [24] Monica, S., & Bergenti, F. (2019). Hybrid indoor localization using WiFi and UWB technologies. *Electronics*, 8(3), 334.
- [25] Retscher, G., Gikas, V., Hofer, H., Perakis, H., & Kealy, A. *Range validation of UWB and Wi-Fi for integrated indoor positioning. Appl. Geomat. 11 (2), 187–195 (2019).*
- [26] Álvarez-Merino, C. S., Luo-Chen, H. Q., Khatib, E. J., & Barco, R. (2021). WiFi FTM, UWB and cellular-based radio fusion for indoor positioning. *Sensors*, 21(21), 7020.
- [27] Poullose, A., Kim, J., & Han, D. S. (2019). A sensor fusion framework for indoor localization using smartphone sensors and Wi-Fi RSSI measurements. *Applied Sciences*, 9(20), 4379.
- [28] Liu, J., Yang, Z., Zlatanova, S., Li, S., & Yu, B. (2025). Indoor Localization Methods for Smartphones with Multi-Source Sensors Fusion: Tasks, Challenges, Strategies, and Perspectives. *Sensors*, 25(6), 1806.
- [29] Wei, B., Gao, M., Li, F., Luo, C., Wang, S., & Zhang, J. (2024). rWiFiSLAM: effective WiFi ranging based SLAM system in ambient environments. *IEEE Robotics and Automation Letters*.
- [30] Yoon, J. H., Kim, H. J., Lee, D. S., & Kwon, S. K. (2024). Indoor Positioning Method by CNN-LSTM of Continuous Received Signal Strength Indicator. *Electronics*, 13(22), 4518.
- [31] Thenuardi, D., & Soewito, B. (2020). Indoor positioning system using WKNN and LSTM combined via ensemble learning. *Advances in Science, Technology and Engineering Systems Journal*, 6(1), 242-249.
- [32] Poullose, A., & Han, D. S. (2020). Hybrid deep learning model based indoor positioning using Wi-Fi RSSI heat maps for autonomous applications. *Electronics*, 10(1), 2.

- [33] Emad-ud-din, M. (2024). Hybrid CNN-LSTM based Indoor Pedestrian Localization with CSI Fingerprint Maps. *arXiv preprint arXiv:2412.13601*.
- [34] Hoang, M. T., Yuen, B., Ren, K., Dong, X., Lu, T., Westendorp, R., & Reddy, K. (2020). A CNN-LSTM quantifier for single access point CSI indoor localization. *arXiv preprint arXiv:2005.06394*.
- [35] Li, L., & Seo, W. (2021, October). Deep learning and transfer learning for skin cancer segmentation and classification. In *2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE)* (pp. 1-5). IEEE.
- [36] Chowdhury, M. M. U., Erden, F., & Guvenc, I. (2019, November). RSS-based Q-learning for indoor UAV navigation. In *MILCOM 2019-2019 IEEE Military Communications Conference (MILCOM)* (pp. 121-126). IEEE.
- [37] Salimibeni, M., & Mohammadi, A. (2022). Hybrid indoor localization via reinforcement learning-based information fusion. *arXiv preprint arXiv:2210.15132*.
- [38] Li, Y., Hu, X., Zhuang, Y., Gao, Z., Zhang, P., & El-Sheimy, N. (2019). Deep reinforcement learning (DRL): Another perspective for unsupervised wireless localization. *ieee internet of things journal*, 7(7), 6279-6287.
- [39] Lin, X., Gan, J., Jiang, C., Xue, S., & Liang, Y. (2023). Wi-Fi-based indoor localization and navigation: A robot-aided hybrid deep learning approach. *Sensors*, 23(14), 6320.
- [40] Cai, C., Fu, M., Meng, X., Jia, C., & Pei, M. (2023). Indoor high-precision visible light positioning system using Jaya algorithm. *Mathematical Biosciences and Engineering*, 20(6), 10358-10375.
- [41] Lin, B., Yang, J., Nie, K., Pan, Y., Chao, J., Luo, J., ... & Ghassemlooy, Z. (2024). NLOS visible light positioning and communication based on LoRa modulation. *Optics Express*, 32(14), 24128-24143.
- [42] Li, C., Zhang, C., Chen, B., Xu, S., Xu, L., & Yan, B. (2024). Ultrasonic Array-Based Multi-Source Fusion Indoor Positioning Technology. *Sensors*, 24(20), 6641.
- [43] Zhang, F., Li, J., Zhang, X., Duan, S., & Yang, S. H. (2025). Indoor Fusion Positioning Based on "IMU-Ultrasonic-UWB" and Factor Graph Optimization Method. *arXiv preprint arXiv:2503.12726*.
- [44] Su, S., Zhao, F., & Jia, H. W. (2014). Improved indoor Ultrasonic Positioning for Smartphones Using TDOA. *Applied Mechanics and Materials*, 614, 484-489.
- [45] van de Laar, F., & Klabunde, K. (2024). Location Awareness in HealthCare. In *Intelligent Secure Trustable Things* (pp. 253-284). Cham: Springer Nature Switzerland.
- [46] Martín-Gorostiza, E., García-Garrido, M. A., Pizarro, D., Salido-Monzú, D., & Torres, P. (2019). An indoor positioning approach based on fusion of cameras and infrared sensors. *Sensors*, 19(11), 2519.
- [47] Arbula, D., & Ljubic, S. (2020). Indoor localization based on infrared angle of arrival sensor network. *Sensors*, 20(21), 6278.
- [48] Pahlavan, K., Li, X., & Makela, J. P. (2002). Indoor geolocation science and technology. *IEEE communications magazine*, 40(2), 112-118.
- [49] Honore, A. A., Thomas, R. W., Martin, R. K., & Kurkowski, S. H. (2009, October). Implementation of collaborative RF localization using a software-defined radio network. In *MILCOM 2009-2009 IEEE Military Communications Conference* (pp. 1-7). IEEE.

- [50] Drane, C., Macnaughtan, M., & Scott, C. (1998). Positioning GSM telephones. *IEEE Communications magazine*, 36(4), 46-54.
- [51] "TOA mode!". (accessed. <http://www.ciscopky.org/network/wireless/ShenWangLaoZhongDeMoXianDin>).
- [52] Gallagher, T., Wise, E., Li, B., Dempster, A. G., Rizos, C., & Ramsey-Stewart, E. (2012, November). Indoor positioning system based on sensor fusion for the blind and visually impaired. In *2012 International Conference on Indoor Positioning and Indoor Navigation (IPIN)* (pp. 1-9). IEEE.
- [53] Kaemarungsi, K., & Krishnamurthy, P. (2004, August). Properties of indoor received signal strength for WLAN location fingerprinting. In *The First Annual International Conference on Mobile and Ubiquitous Systems: Networking and Services, 2004. MOBIQUITOUS 2004.* (pp. 14-23). IEEE.
- [54] Honkavirta, V., Perala, T., Ali-Loytty, S., & Piché, R. (2009, March). A comparative survey of WLAN location fingerprinting methods. In *2009 6th workshop on positioning, navigation and communication* (pp. 243-251). IEEE.
- [55] Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- [56] Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
- [57] Liu, S., Ren, Q., Li, J., & Xu, H. (2021, December). DeepLoc: A Deep Neural Network-based Indoor Positioning Framework. In *2021 IEEE 23rd Int Conf on High Performance Computing & Communications; 7th Int Conf on Data Science & Systems; 19th Int Conf on Smart City; 7th Int Conf on Dependability in Sensor, Cloud & Big Data Systems & Application (HPCC/DSS/SmartCity/DependSys)* (pp. 1735-1740). IEEE.