



BIBLIOTHÈQUE

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

Mise en garde

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

Warning

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

UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

ÉCOLE DE GÉNIE

**LOCALISATION DE VÉHICULES AUTONOMES DANS UN
ENVIRONNEMENT INDUSTRIEL SOUTERRAIN**

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE

DE LA MAÎTRISE EN INGÉNIERIE

PAR

MOHAMED MADI

SEPTEMBRE 2023

REMERCIEMENTS

À l'issue de la rédaction de cette recherche, j'adresse mes remerciements à toutes les personnes qui ont cru en moi et qui m'ont permis d'arriver au bout de cette thèse.

Je tiens à remercier tout d'abord mon directeur de recherche, professeur *Nahi Kandil*, pour m'avoir fait confiance dès le début, pour ses multiples conseils et pour sa participation scientifique.

Je suis également reconnaissant à mon codirecteur de thèse, professeur *Nadir Hakem*, pour m'avoir guidé et encouragé tout au long de ce travail. J'aimerais également lui dire à quel point j'ai apprécié toutes les heures qu'il a consacrées à diriger cette recherche.

Je remercie également le responsable du laboratoire *Mohamed Ailas* qui m'a aidé en mettant à ma disposition le matériel et les ressources logiques nécessaires pour mener à bien mon projet.

Un grand merci à mes collègues *Ali Issa, Nour Zaarour, Mohamad El Hajj Khalil, Bassam Zahreddine, Nabih Allaw* et *Ali Khalaf* pour la bonne ambiance de travail qui a rendu cette formation très sympathique.

TABLE DES MATIÈRES

Introduction	4
I. Motivation et problématique :.....	4
II. Solutions proposées :.....	6
III. Méthodologie :	7
IV. Hypothèses :	9
Chapitre 1	10
État de l'Art :.....	10
1.1. Localisation indoor par BLE basée sur le RSSI amélioré et la trilatération :	10
1.1.1. Aperçu :	10
1.1.2. Description du modèle et résultats :	11
1.2. Localisation tridimensionnelle fusionnée de capteurs utilisant l'IMU, la caméra et le LiDAR :.....	12
1.2.1. Aperçu :	12
1.2.2. Description du modèle et résultats	13
1.3. Localisation de robot en intérieur par fusion de capteurs RSSI/IMU :	14
1.3.1. Aperçu.....	14
1.3.2. Description du modèle et résultats	15
1.4. Système de Positionnement des Mines de Charbon Souterraines Basé sur l'Algorithme de Positionnement RSSI Amélioré par l'Apprentissage BP : 17	
1.4.1. Aperçu :	17
1.4.2. Description du modèle et résultats :.....	17

Chapitre 2	20
<i>Outils Pour la Fusion de Capteurs :</i>	20
2.1. Aperçu :	20
2.2. Matériel et logiciel :	22
2.2.1. Unité de mesure inertielle (IMU).....	22
2.2.2. Bluetooth à Basse Consommation (BLE):	25
2.2.3. MATLAB :	28
2.2.4. Téléphone Intelligent:	29
Chapitre 3	31
<i>Architecture de Fusion de Capteurs :</i>	31
3.1. Trilatération:	33
3.2. Extended Kalman Filter (EKF):	35
3.2.1. Étape de prédiction	36
3.2.2. Étape de mise à jour.....	38
3.2.3. Application de EKF dans mon système	39
3.3. Unscented Kalman Filter (UKF):	44
3.3.1. Étape de prédiction	47
3.5.1. Étape de mise à jour.....	47
3.5.1. Application de UKF dans mon système.....	49
3.4. Différence entre EKF et UKF :	54
3.5. Calcul d'Erreur :	56
3.5.1. Erreur de Distance Euclidienne	56
3.5.2. RMSE	57
3.5.3. Erreur Relative.....	57
Chapitre 4	59
<i>Tests et Résultats</i>	59
4.1. Simulation:	59

4.1.1.	Trilatération	61
4.1.2.	EKF.....	62
4.1.3.	UKF	63
4.2.	Environnement universitaire :	64
4.2.1.	Scénarios.....	64
4.2.2.	Résultats.....	66
4.2.3.	Comparaison des résultats avec d'autres travaux existants.....	74
4.3.	Environnement Industrielle souterraine:.....	76
4.3.1.	Scénario	77
4.3.2.	Résultats.....	79
4.3.3.	Pour mieux comprendre les résultats :	86
4.3.4.	Comparaison des résultats avec d'autres travaux existants :.....	89
	<i>Conclusion</i>.....	90
	<i>Références</i>	93

LISTE DES FIGURES

FIGURE 1: SCHÉMA FONCTIONNEL.....	8
FIGURE 2: ILLUSTRATION DU PROCESSUS DE FILTRAGE SPECIFIQUE.....	11
FIGURE 3: ERREURS DE TRAJECTOIRE SIMULEES POUR LES TROIS SCENARIOS.....	13
FIGURE 4: CARTE RECONSTRUITE A PARTIR DU RESULTAT DE LA FUSION DES CAPTEURS RSSI/IMU.....	15
FIGURE 5: ERREUR ABSOLUE DANS LES DIRECTIONS X ET Y.....	16
FIGURE 6 : RELATION ENTRE LA LARGEUR DE LA CHAUSSEE ET L'ERREUR DE POSITIONNEMENT.....	18
FIGURE 7: UNITE DE MESURE INERTIELLE [9].....	22
FIGURE 8: UN ASSORTIMENT D'IBEAONS DE DIFFERENTS FOURNISSEURS.....	26
FIGURE 9: MÉTHODE DE TRILATÉRATION.....	33
FIGURE 10: SCÉNARIO APRÈS APPLICATION DE L'APPROXIMATION DE TAYLOR À LA LINÉARISATION D'UNE FONCTION.....	36
FIGURE 11: SCHEMA QUI MONTRE L'ALGORITHME DU EKF.....	41
FIGURE 12: SCHEMA QUI MONTRE L'ALGORITHME DU EKF AVEC LES EQUATIONS.....	41
FIGURE 13: SCHEMA QUI MONTRE L'ALGORITHME DU UKF.....	51
FIGURE 14: SCHEMA QUI MONTRE L'ALGORITHME DU UKF AVEC LES EQUATIONS.....	51
FIGURE 15: SCÉNARIO D'APPROXIMATION GAUSSIENNE EN EKF AUTOUR DE LA MOYENNE.....	54
FIGURE 16: SCENARIO D'APPROXIMATION GAUSSIENNE AUTOUR DE LA MOYENNE ET D'AUTRES POINTS SIGMA.....	55
FIGURE 17: COMPARAISON DU CALCUL DU GAIN DE KALMAN EN EKF ET EN UKF.....	56
FIGURE 18: SCÈNE D'EXPÉRIENCE DE LA SIMULATION.....	59
FIGURE 19: TRAJECTOIRE REELLE DU VEHICULE LORS DE LA SIMULATION.....	60
FIGURE 20: TRAJECTOIRE ESTIMEE PAR TRILATERATION COMPAREE A LA TRAJECTOIRE REELLE.....	61
FIGURE 21: TRAJECTOIRE ESTIMEE PAR EKF COMPAREE A LA TRAJECTOIRE REELLE.....	62
FIGURE 22: TRAJECTOIRE ESTIMEE PAR UKF COMPAREE A LA TRAJECTOIRE REELLE.....	63
FIGURE 23: LE COULOIR DANS L'UNIVERSITE.....	64
FIGURE 24: PREMIER SCENARIO DANS L'UNIVERSITE.....	65
FIGURE 25: DEUXIEME SCENARIO DANS L'UNIVERSITE.....	66
FIGURE 26: ESTIMATION DU COEFFICIENT D'ENVIRONNEMENT DANS L'UNIVERSITÉ.....	67
FIGURE 27: PREMIÈRE COMPAGNE DE MESURES.....	68
FIGURE 28: L'ERREUR PAR RAPPORT AU TEMPS.....	68
FIGURE 29: PREMIERE COMPAGNE DE MESURES.....	69

FIGURE 30: L'ERREUR PAR RAPPORT AU TEMPS	69
FIGURE 31: COMPARAISON ENTRE LES DEUX ERREUR PAR RAPPORT AU TEMPS	70
FIGURE 32: SECONDE COMPAGNE DE MESURES.....	71
FIGURE 33: L'ERREUR PAR RAPPORT AU TEMPS	71
FIGURE 34: SECONDE COMPAGNE DE MESURES.....	72
FIGURE 35: L'ERREUR PAR RAPPORT AU TEMPS	72
FIGURE 36: COMPARAISON ENTRE LES DEUX ERREUR PAR RAPPORT AU TEMPS.....	73
FIGURE 37: PHOTOGRAPHIE DE L'ENVIRONNEMENT MINIER.....	76
FIGURE 38: PHOTOGRAPHIE DU VEHICULE DANS LA MINE LORS DES MESURES.....	76
FIGURE 39: PREMIER SCENARIO DANS LA MINE.....	77
FIGURE 40: DEUXIÈME SCENARIO DANS LA MINE.....	78
FIGURE 41: ESTIMATION DU COEFFICIENT D'ENVIRONNEMENT DANS LA MINE.....	79
FIGURE 42: PREMIERE COMPAGNE DE MESURES.....	80
FIGURE 43: L'ERREUR PAR RAPPORT AU TEMPS	80
FIGURE 44: PREMIÈRE COMPAGNE DE MESURES.....	81
FIGURE 45: L'ERREUR PAR RAPPORT AU TEMPS	81
FIGURE 46: COMPARAISON ENTRE LES DEUX ERREUR PAR RAPPORT AU TEMPS.....	82
FIGURE 47: SECONDE COMPAGNE DE MESURES.....	83
FIGURE 48: L'ERREUR PAR RAPPORT AU TEMPS	83
FIGURE 49: SECONDE COMPAGNE DE MESURES.....	84
FIGURE 50: L'ERREUR PAR RAPPORT AU TEMPS	84
FIGURE 51: COMPARAISON ENTRE LES DEUX ERREUR PAR RAPPORT AU TEMPS.....	85
FIGURE 52: TRAJECTOIRE ESTIMÉE COMPARÉE À LA TRAJECTOIRE RÉELLE EN ANNULANT 2 BALISES DANS LA MINE.....	86
FIGURE 53: L'ERREUR PAR RAPPORT AU TEMPS	86
FIGURE 54: TRAJECTOIRE ESTIMÉE COMPARÉE À LA TRAJECTOIRE RÉELLE EN ANNULANT TOUS LES BALISES DANS LA MINE.....	88

LISTE DES TABLEAUX

TABLEAU I: CARACTERISTIQUES DES CAPTEURS DU TELEPHONE UTILISE.....	30
TABLEAU II: COMPARAISON DES PERFORMANCES DE L'EKF ET DU UKF DANS LES DEUX SCENARIOS DANS L'UNIVERSITE.....	74
TABLEAU III: COMPARAISON DES PERFORMANCES DE L'EKF ET DU UKF DANS LES DEUX SCÉNARIOS DANS LA MINE.....	89

RÉSUMÉ

De nos jours, l'industrie minière est confrontée à des défis complexes liés à l'amélioration de l'efficacité et de la sécurité dans l'exploitation minière souterraine. Toutefois, un défi majeur persiste dans la localisation précise des véhicules autonomes évoluant au sein de ces environnements miniers souterrains, en raison de l'absence de communication externe ou de signalisation provenant du système de positionnement global (GPS).

Cette étude présente le développement et l'évaluation d'un système de localisation destiné à être intégré aux véhicules autonomes opérant dans des environnements de mines souterraines. Le système utilise l'unité de mesure inertielle (IMU) et la technologie de Bluetooth à faible consommation d'énergie (BLE). Sa performance a été évaluée au moyen d'expérimentations menées à la fois dans un cadre universitaire contrôlé et au sein d'un environnement industriel souterrain. L'objectif principal de cette recherche est de concevoir un système de localisation robuste et précis pour permettre aux véhicules autonomes d'effectuer des tâches dans les mines souterraines sans dépendre du signal GPS. Les résultats recueillis attestent de la performance du système, lequel s'avère apte à assurer une localisation précise et fiable des véhicules autonomes en milieu minier souterrain.

Cette recherche peut contribuer à l'amélioration de l'efficacité et de la sécurité au sein de l'exploitation minière souterraine, en offrant la possibilité aux véhicules autonomes de se déplacer de manière autonome et précise.

ABSTRACT

Nowadays, the mining industry is facing complex challenges related to improving efficiency and safety in underground mining operations. However, a major challenge persists in accurately locating autonomous vehicles operating within these underground mining environments due to the absence of external communication or signaling from the Global Positioning System (GPS).

This study presents the development and evaluation of a localization system intended to be integrated into autonomous vehicles operating in underground mine environments. The system utilizes Inertial Measurement Unit (IMU) and low-energy Bluetooth technology (BLE). Its performance was evaluated through experiments conducted both in a controlled university setting and within an industrial underground environment. The primary goal of this research is to design a robust and accurate localization system to enable autonomous vehicles to perform tasks in underground mines without relying on the GPS signal. The collected results confirm the system's performance, which proves capable of ensuring precise and reliable localization of autonomous vehicles in underground mining conditions.

This research can contribute to improving efficiency and safety in underground mining operations by providing autonomous vehicles with the ability to move autonomously and accurately.

LISTE DES VARIABLES

GPS	Global Positioning System (Système de Positionnement Global)
Wi-Fi	Wireless Fidelity (Fidélité Sans Fil)
BLE	Bluetooth Low Energy (Bluetooth à Basse Consommation)
IMU	Inertial Measurement Unit (Unité de Mesure Inertielle)
RSSI	Received Signal Strength Indicator (Indicateur de Force du Signal Reçu)
EKF	Extended Kalman Filter
UKF	Unscented Kalman Filter
RMSE	Root Mean Square Error (Racine de L'écart Quadratique Moyen)
WAA	Weighted Average Approach (Approche de la Moyenne Pondérée)
2D	Two Dimensional (Environnement Bidimensionnel)
3D	Three Dimensional (Environnement Tridimensionnel)
LiDAR	Light Detection and Ranging (Détection et Télémétrie Laser)
WKF	Weighted Kalman Filter
GFSK	Gaussian Frequency-Shift Keying (modulation par déplacement de fréquence gaussienne)
WLAN	Wireless Local Area Network (Réseau Local Sans Fil)
MAC	Media Access Control (Contrôle d'Accès au Support)
AoA	Angle of Arrival (Angle d'Arrivée)
CDF Cumulative)	Cumulative Distribution Function (Fonction de Répartition Cumulative)

INTRODUCTION

I. Motivation et problématique :

Le Canada joue un rôle significatif dans l'économie nationale en contribuant de manière conséquente, avec plusieurs milliards de dollars, au produit intérieur brut annuel du pays, tout en générant un nombre considérable d'emplois, tant directs qu'indirects. Le pays occupe une position de premier plan dans la production mondiale de métaux précieux, de nickel, de cuivre, d'uranium et de diamants.

L'industrie emploie 392 000 travailleurs directement et 327 000 indirectement dans les industries minières, de fonderie, de fabrication et de traitement des minéraux à l'échelle nationale [1]. La localisation précise des véhicules autonomes dans les mines souterraines constitue un enjeu de première importance pour garantir la sécurité optimale des activités minières. Les mines souterraines étant complexes et potentiellement dangereux pour les travailleurs humains, l'intégration de véhicules autonomes offre une opportunité significative de réduire considérablement les risques d'accidents et de blessures et permet d'éliminer la nécessité pour les travailleurs de se déplacer dans des zones potentiellement instables ou présentant des dangers.

Néanmoins, l'obtention d'une localisation précise des véhicules autonomes dans l'environnement minier demeure un défi complexe en raison de conditions contraignantes présentes au sein des mines. Des facteurs tels que les interférences des signaux radio et les obstacles physiques entravent considérablement la tâche. Les systèmes traditionnels de localisation, notamment le système de positionnement global (GPS), se révèlent inefficaces dans les mines souterraines, où les signaux GPS ne parviennent pas à pénétrer sous la surface. Par ailleurs, les structures géologiques, tels que les parois rocheuses, ainsi que la présence d'équipements et de machines, peuvent

altérer ou bloquer les signaux de localisation, complexifiant davantage la détermination précise de la position des véhicules autonomes [2].

D'autres solutions existantes pour la localisation des véhicules autonomes dans les mines souterraines reposent généralement sur des technologies telles que le Wi-Fi, le BLE, les capteurs IMU, etc. ou une combinaison de plusieurs capteurs. Cependant, ces solutions présentent des limitations en termes de précision, car elles reposent soit uniquement sur un seul de ces outils (par exemple, le BLE, le Wi-Fi, ou les IMU), soit les techniques de fusion de données employées se révèlent peu performantes, ce qui diminue leur efficacité globale.

En outre, ces systèmes choisissent la valeur du coefficient d'environnement, utilisé pour calculer la distance entre BLE, Wi-Fi, etc. et le véhicule, basée sur des mesures faites de différentes distances connues, ce qui peut entraîner des erreurs et nécessiter des modifications du système pour chaque environnement dans lequel il sera installé.

Pour atteindre une efficacité optimale, un système de localisation doit pouvoir garantir une précision d'environ 1 mètre, voire moins. Malheureusement, cette exigence s'avère difficile à atteindre pour les solutions actuellement disponibles.

II. Solutions proposées :

Le développement de solutions innovantes visant à assurer la localisation précise des véhicules autonomes dans les mines souterraines est un enjeu crucial pour l'industrie minière. Les signaux radio sont souvent limités dans ces environnements complexes et dangereux, rendant ainsi la détermination de la position des véhicules autonomes une tâche ardue.

Cependant, l'utilisation de l'unité de mesure inertielle (IMU) et des valeurs de l'indicateur de force du signal reçu (RSSI) des balises Bluetooth à basse consommation (BLE) offre une solution prometteuse en vue de parvenir à une localisation précise des véhicules autonomes au sein des mines souterraines.

L'IMU est un capteur qui mesure les mouvements et les rotations d'un objet, tel qu'un véhicule autonome, en utilisant des capteurs de gyroscope, d'accéléromètre et de magnétomètre. Parallèlement, les balises Bluetooth à basse consommation (BLE) sont de petits dispositifs émettant un signal radio, dont l'utilisation permet d'estimer la distance séparant le véhicule autonome de la balise. De surcroît, le système est doté d'une capacité d'automatisation et d'adaptation, lui permettant de s'intégrer aisément dans divers environnements où il sera déployé.

Les filtres « Extended Kalman Filter » (EKF) et « Unscented Kalman Filter » (UKF) sont des outils de fusion de données avancés qui peuvent être utilisés pour combiner les mesures IMU et RSSI, en vue d'obtenir une estimation précise de la position du véhicule autonome [3]. Le EKF est une extension du filtre de Kalman classique, qui peut incorporer en compte les non-linéarités présentes dans les modèles de système et de mesure. Par ailleurs, le UKF est une version plus avancée du filtre de EKF, offrant une meilleure capacité à modéliser de manière précise les systèmes non linéaires.

De plus, ces filtres présentent l'avantage de pouvoir estimer de manière automatique le coefficient d'environnement 'n', lequel est employé en conjonction avec la valeur RSSI pour évaluer la distance. Le coefficient d'environnement 'n' représente une variable qui traduit la perte de signal induite par divers facteurs, tels que la présence d'obstacles, l'absorption et la réfraction. L'estimation précise du coefficient d'environnement 'n' est essentielle pour calculer la distance exacte entre le véhicule autonome et la balise, ce qui est nécessaire pour estimer la position précise du véhicule.

L'utilisation de l'IMU et des valeurs RSSI des balises BLE, combinées avec les filtres EKF et UKF, peut fournir une solution prometteuse pour la localisation précise des véhicules autonomes dans les mines souterraines. Cette technologie peut considérablement améliorer la sécurité et l'efficacité opérationnelle de l'industrie minière canadienne en réduisant les risques d'accidents et en améliorant la productivité dans ces environnements complexes et dangereux.

III. Méthodologie :

La méthodologie élaborée est exposée dans la Figure 1, sous la forme d'un schéma fonctionnel, détaillant de manière exhaustive le fonctionnement du système. Ce schéma a été élaboré pour mettre en lumière les différentes étapes et composantes du système, en mettant en évidence les connexions entre les différentes parties.

Tout d'abord, le système va scanner toutes les balises BLE dans l'environnement et récupérer leur RSSI. De manière simultanée, il procède à la récupération des mesures provenant des capteurs IMU (accéléromètre, gyroscope, magnétomètre).

Dans le bloc n°1, le système va vérifier s'il y a une lecture de RSSI provenant de 3 balises ou plus, Si cette condition est satisfaite, le système passera au bloc n°5 où il sélectionnera les trois valeurs de RSSI les plus faibles parmi celles recueillies. En revanche, si seulement deux valeurs de RSSI sont disponibles (correspondant aux

balises BLE les plus proches), le système passera au bloc n°2 et sélectionnera la plus petite valeur de RSSI parmi celles recueillies. La valeur de RSSI obtenue sera acheminée vers le bloc n°3, où elle sera conjuguée avec les données issues de l'accéléromètre, du magnétomètre et du gyroscope. Par le biais de l'utilisation de l'EKF/UKF, une fusion de ces données sera réalisée pour aboutir à une estimation consolidée. Si, toutefois, le système opte pour la trajectoire du bloc n°5, il collectera également des mesures provenant de l'IMU et les fusionnera avec la plus petite valeur de RSSI parmi les trois, au sein du bloc n°6. Ensuite, au bloc n°7, nous effectuerons la trilatération en utilisant ces 3 valeurs de RSSI, et dans le bloc n°8, nous utiliserons la méthode de « weighted average approach » (WAA) pour fusionner l'estimation UKF/EKF avec l'estimation de la trilatération. Enfin, la trajectoire, la vitesse estimée et le coefficient environnemental "n" seront affichés, avec le RMSE et l'erreur relative de chaque filtre qui seront également calculés.

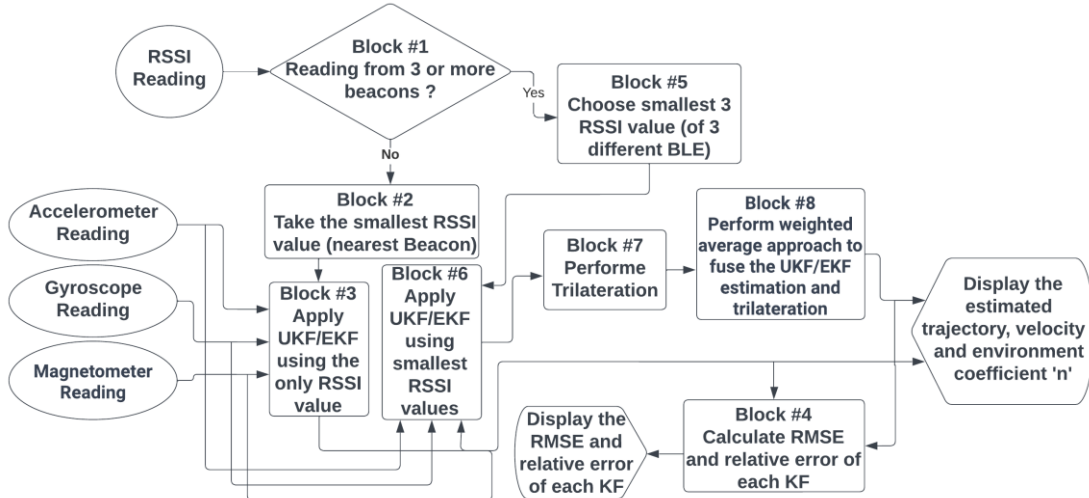


Figure 1: Schéma Fonctionnel.

IV. Hypothèses :

Hypothèse 1 : La fusion des données provenant du capteur IMU et des valeurs RSSI issues de la technologie BLE, à travers l'utilisation des filtres EKF et UKF, permet d'aboutir à des estimations de localisation précises et fiables pour les véhicules autonomes évoluant au sein des mines souterraines.

Hypothèse 2 : L'estimation du coefficient d'environnement 'n' à l'aide de l'EKF ou de l'UKF pour le calcul de la distance entre BLE et véhicule pour rendre le system automatique.

Hypothèse 3 : Le WAA pour fusionner les estimations de localisation de l'EKF ou de l'UKF avec les résultats de trilatération fournira une estimation robuste et précise.

Hypothèse 4 : L'installation des balises BLE tous les 50 mètres ou plus (dépend de la distance maximale que le BLE peut être détecté dans l'environnement) dans les mines souterraines sur les trajectoires droites, ainsi que la présence de trois balises BLE dans les zones de virage.

CHAPITRE 1

ÉTAT DE L'ART :

Dans le contexte actuel de l'industrie minière, l'automatisation et la robotisation des processus sont de plus en plus cruciales pour améliorer la sécurité, l'efficacité et la rentabilité des opérations. Les véhicules autonomes jouent un rôle clé dans cette transformation. Néanmoins, la localisation précise de ces véhicules dans les environnements souterrains demeure un défi de taille à relever. Ce mémoire aborde cette problématique en proposant une approche de localisation basée sur la fusion des données de capteurs inertiels (IMU) et des valeurs de puissance de signal reçues (RSSI) provenant de la technologie des balises Bluetooth Low Energy (BLE). Cette introduction à l'état de l'art présente les recherches et les développements antérieurs relatifs à la localisation des véhicules autonomes et aux technologies utilisées, notamment les capteurs IMU, les balises BLE, et les algorithmes de fusion de données tels EKF et UKF.

1.1. Localisation indoor par BLE basée sur le RSSI amélioré et la trilatération :

1.1.1. Aperçu :

Le Bluetooth Low Energy (BLE) fonctionnant dans les bandes ISM peut subir des fluctuations de signal qui affectent l'indicateur d'intensité du signal reçu (RSSI). Étant donné que RSSI est la backbone des algorithmes de localisation les plus largement utilisés, ces variations affectent négativement la précision de l'estimation de la localisation. Ce document propose une solution de localisation précise en intérieur pour

des applications médicales. Ce travail montre comment surmonter l'instabilité RSSI due à l'appareil et à l'environnement, et comment calculer la distance entre les destinations. La distance est utilisée pour obtenir les coordonnées de la cible à l'aide d'un algorithme de trilatération améliorée montrée dans la Figure 2 [4].

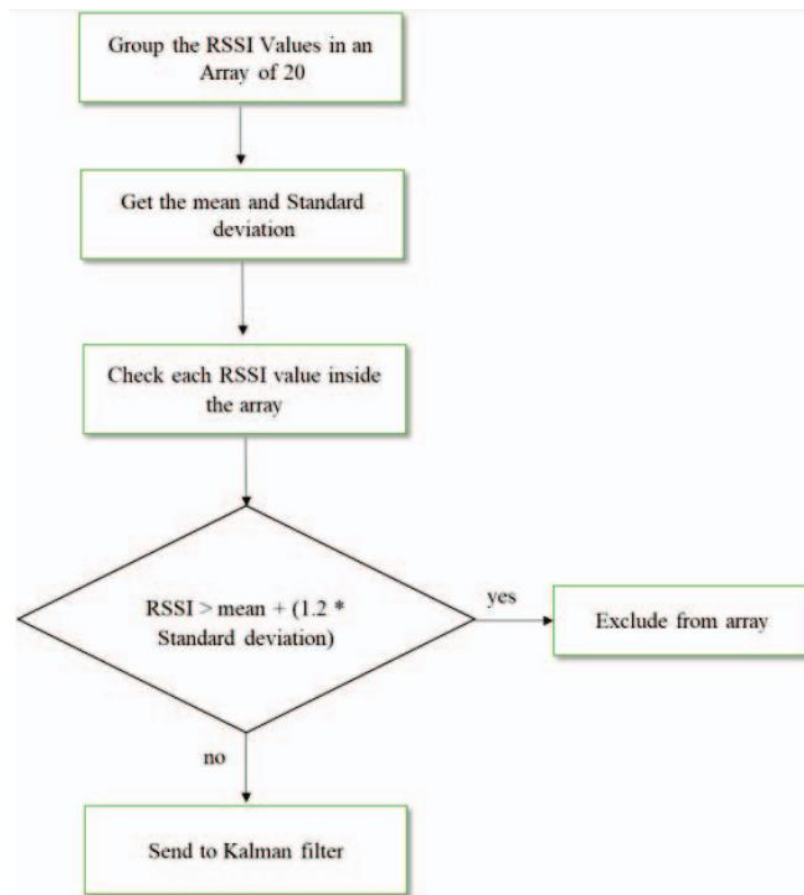


Figure 2: Illustration du processus de filtrage spécifique.

1.1.2. Description du modèle et résultats :

La localisation proposée est basée sur les éléments suivants : balayage d'un seul canal publicitaire BLE, introduction d'un filtre pour supprimer les fortes fluctuations, un « Weighted Kalman Filter » (WKF) avant le calcul de la distance, et pour le calcul

de la position, weighted trilatération. Les résultats expérimentaux ont attesté que le système proposé présente une erreur inférieure à 0,5 m pour 95 % des mesures effectuées dans une chambre de dimensions 4,4 x 3 m². Par ailleurs, le système démontre une évolutivité avantageuse et une optimisation remarquable en ce qui concerne le coût et la consommation énergétique.

1.2. Localisation tridimensionnelle fusionnée de capteurs utilisant l'IMU, la caméra et le LiDAR :

1.2.1. Aperçu :

L'estimation de la position et de l'orientation d'une plate-forme mobile dans un environnement tridimensionnel (3D) est d'une grande importance dans de nombreux domaines tels que la robotique et la détection. Pour accomplir cette tâche, il est courant d'utiliser un ou plusieurs capteurs. La méthode proposée intègre les données des unités de mesure inertielle (IMU), des caméras et des capteurs LiDAR (Light Detection and Ranging) afin de surmonter les limitations et de compléter les forces de chaque capteur individuel.

Les auteurs proposent un nouvel algorithme qui fusionne les informations obtenues à partir des IMU, des caméras et des capteurs LiDAR pour générer une représentation 3D complète et précise de l'environnement. Les données de l'IMU fournissent des informations sur l'orientation et le mouvement du système, tandis que la caméra capture des informations visuelles et que le capteur LiDAR génère des nuages de points 3D haute résolution. Le processus de fusion tire parti de la nature complémentaire de ces capteurs, ce qui permet d'obtenir une solution de localisation plus fiable et précise [5].

1.2.2. Description du modèle et résultats :

Les auteurs ont combiné avec des données provenant de caméras et de capteurs inertiels dans un EKF et ont montré qu'ils pouvaient améliorer la pose globale 3D estimée, même en présence d'une estimation imparfaite issue du capteur LiDAR 2D.

Pour valider l'efficacité de leur méthode proposée, les auteurs ont entrepris une série d'expérimentations, impliquant l'utilisation conjointe de données simulées et réelles. Ils comparent également ce scénario avec le remplacement du LiDAR 2D par le LiDAR 3D avec des propriétés similaires, mais la possibilité de créer une estimation 3D complète.

Pose		Error		
		<i>IMU & Camera</i>	<i>IMU & Camera & 2D LiDAR</i>	<i>IMU & Camera & 3D LiDAR</i>
Position (m)	x	0.1572	0.0298	0.0218
	y	0.1260	0.0297	0.0101
	z	0.1999	0.0900	0.0246
Orientation (rad)	yaw	0.0022	0.0013	0.0012
	pitch	0.0031	0.0026	0.0016
	roll	0.0037	0.0024	0.0012

Figure 3: Erreurs de trajectoire simulées pour les trois scénarios.

Les résultats montrent que la méthode de localisation 3D fusionnée par capteurs améliore considérablement la précision et la robustesse de la localisation par rapport à l'utilisation des capteurs individuels seuls. L'approche de fusion de capteurs permet de pallier efficacement les limitations de chaque type de capteur, telles que la dérive de l'IMU, les occlusions de la caméra et le bruit du LiDAR. Cela rend la méthode appropriée pour diverses applications en robotique, véhicules autonomes et systèmes de navigation.

La méthode proposée utilisant LiDAR présente des erreurs plus petites que les études précédentes qui ne fusionnaient que la caméra et l'IMU comme le montre la

Figure 3. La rapidité du capteur LiDAR permet de mettre à jour l'état du filtre de manière plus fréquente, étant donné que la caméra est moins réactive en comparaison.

1.3. Localisation de robot en intérieur par fusion de capteurs RSSI/IMU :

1.3.1. Aperçu :

Le document aborde le problème de la localisation des robots mobiles dans des environnements intérieurs où le GPS n'est pas faisable. La solution proposée implique la fusion de capteurs entre RSSI (indicateur de force du signal reçu) provenant d'un réseau local sans fil (WLAN) et une unité de mesure inertielle (IMU) pour améliorer la précision et la robustesse de la localisation des unités mobiles. L'algorithme du filtre EKF est utilisé pour la fusion des capteurs.

L'obtention d'une localisation précise des robots mobiles revêt une importance cruciale pour des applications variées, incluant les systèmes autonomes, les robots industriels et les véhicules autonomes. Néanmoins, dans les environnements intérieurs où l'utilisation du GPS s'avère peu praticable, il devient complexe d'atteindre un niveau de précision adéquat avec l'usage d'un seul capteur. Par conséquent, l'intégration de plusieurs capteurs offre une solution prometteuse pour significativement améliorer la précision et la fiabilité de la localisation des robots mobiles [6].

1.3.2. Description du modèle et résultats :

Les expériences ont été menées dans un environnement intérieur avec une unité mobile équipée d'une IMU à faible coût et d'un module de communication sans fil avec des points d'accès WLAN comme indiqué dans la Figure 4. À plusieurs reprises, l'unité mobile a été déplacée le long d'un parcours préétabli, dans le but de vérifier l'exactitude et l'efficacité de l'algorithme proposé




Figure 4: Carte reconstruite à partir du résultat de la fusion des capteurs RSSI/IMU.

Les résultats obtenus mettent en évidence une nette amélioration de la précision et de la fiabilité de la localisation des unités mobiles grâce à l'approche proposée, comparativement à l'utilisation isolée des RSSI ou des capteurs IMU. En particulier, les erreurs RMSE pour la comparaison entre la sortie estimée des RSSI et les valeurs réelles s'élèvent respectivement à 0,86 mètre dans la direction x et 1,15 mètre dans la direction y. Quant à l'évaluation des erreurs RMSE pour la

comparaison entre les positions estimées et réelles, elles sont respectivement de 0,98 mètre dans la direction x et 1,02 mètre dans la direction y, comme illustré dans la Figure 5. Cette approche exploitant plusieurs capteurs démontre ainsi une considérable amélioration en termes de précision et de fiabilité de la localisation des robots mobiles. Finalement, la méthode proposée a permis d'atteindre une précision RMSE d'environ 1 mètre dans les deux directions x et y.

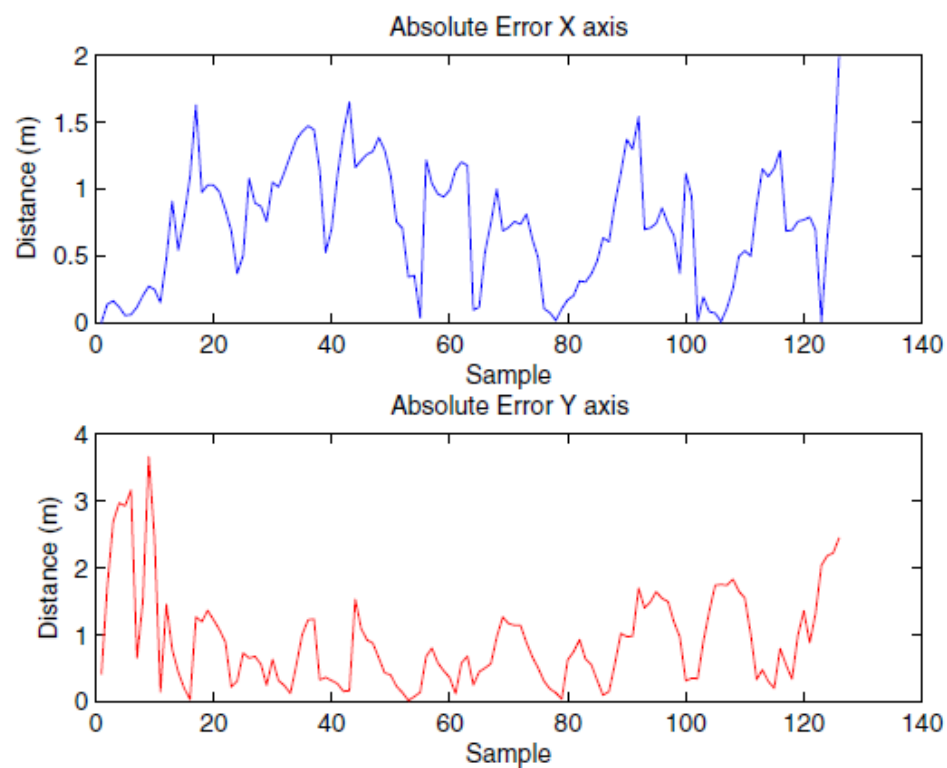


Figure 5: Erreur absolue dans les directions x et y.

1.4. Système de Positionnement des Mines de Charbon Souterraines Basé sur l'Algorithme de Positionnement RSSI Amélioré par l'Apprentissage BP :

1.4.1. Aperçu :

Dans cette section de l'état de l'art, l'attention est portée sur les méthodes actuelles utilisées dans le domaine de la recherche pour la localisation et le suivi des personnes dans les mines de charbon souterraines. Ces mines sont connues pour leur environnement géographique unique et complexe. La configuration encaissée des galeries de mines de charbon, associée à des facteurs tels que les parois inégales, les nombreuses intersections, les variations de topographie, la présence de poussière omniprésente, une forte teneur en gaz et en humidité de l'air, ainsi que l'utilisation intensive de dispositifs de forage, pose des problèmes spécifiques pour les transmissions d'ondes électromagnétiques et la précision de la localisation en temps réel.

1.4.2. Description du modèle et résultats :

Pour relever ces défis, le modèle de localisation souterraine propose deux principaux axes d'amélioration de l'algorithme RSSI traditionnel. D'abord, l'introduction de seuils d'écart-type (TSA et RSA) permet de filtrer et de normaliser les valeurs RSSI en fonction des conditions réelles du terrain. Cette approche prend en compte l'influence des variations environnementales spécifiques à chaque localisation dans la mine, ce qui améliore considérablement la précision des estimations de distance basées sur le RSSI. Ensuite, l'algorithme d'apprentissage BP (Back Propagation) est appliqué pour améliorer la précision globale du système de localisation en minimisant les erreurs entre les valeurs RSSI réelles et estimées.

Pour évaluer les performances du modèle amélioré, des simulations détaillées ont été menées dans un environnement virtuel représentatif d'une mine de charbon

souterraine. Dix nœuds balises ont été préconfigurés à des positions spécifiques et vingt nœuds inconnus ont été répartis aléatoirement dans l'environnement simulé. Les résultats des simulations montrent clairement que l'approche améliorée surpasse de manière significative l'algorithme RSSI traditionnel. La précision globale du système de localisation est nettement améliorée, avec une réduction substantielle des erreurs de positionnement. L'utilisation de seuils d'écart-type permet d'éliminer les erreurs liées aux variations environnementales, tandis que l'algorithme d'apprentissage BP améliore la capacité du système à apprendre et à s'adapter aux changements dans l'environnement de la mine. Ces résultats présentés dans la Figure 6 prometteurs suggèrent que le modèle pourrait être une approche efficace pour améliorer la localisation des personnes dans les mines de charbon souterraines et augmenter la réactivité des équipes de secours lors d'accidents critiques.

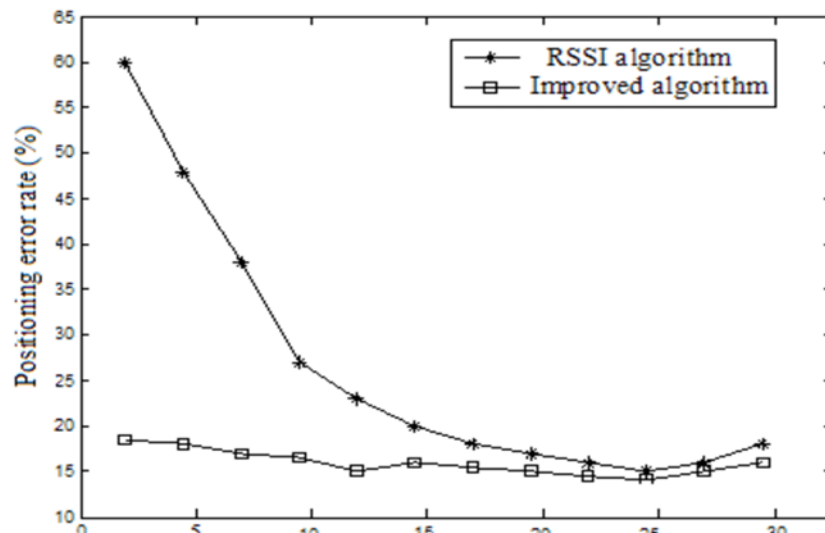


Figure 6 : Relation entre la largeur de la chaussée et l'erreur de positionnement.

L'application du modèle amélioré pourrait avoir un impact significatif sur la sécurité et l'efficacité des opérations dans l'industrie minière, en permettant une meilleure gestion des ressources humaines et une réponse plus rapide aux situations d'urgence. Cependant, il est reconnu que des défis subsistent, tels que l'optimisation

des paramètres du modèle en fonction des conditions spécifiques de chaque mine et l'intégration de technologies de communication sans fil avancées pour améliorer la robustesse du système de localisation dans des conditions extrêmes. De futures recherches seront nécessaires pour explorer ces domaines et approfondir la validation expérimentale du modèle dans des environnements réels de mines de charbon. En conclusion, le modèle de localisation amélioré présente un potentiel prometteur pour renforcer la sécurité et l'efficacité des opérations minières souterraines, ouvrant ainsi la voie à des applications pratiques pour la surveillance et le sauvetage dans ces environnements exigeants.

CHAPITRE 2

OUTILS POUR LA FUSION DE CAPTEURS :

2.1. Aperçu :

L'estimation précise de la localisation représente une préoccupation majeure dans divers domaines d'application, notamment la robotique, la navigation et la surveillance. Dans cette optique, la fusion de capteurs émerge comme une stratégie incontournable consistant à agréger les données provenant de multiples capteurs en vue d'obtenir une estimation plus fiable de la localisation. Cette approche trouve une large adoption dans le but de pallier les limitations inhérentes aux capteurs individuels et d'améliorer la précision globale du processus de localisation.

La fusion de capteurs peut être réalisée en utilisant diverses technologies de capteurs, telles que les capteurs de position (GPS, par exemple), les capteurs inertiels (comme les accéléromètres, les magnétomètres et les gyroscopes) et les capteurs de communication (tels que les balises Bluetooth Low Energy). Chaque type de capteur présente des avantages et des inconvénients en termes de précision, de coût et de complexité de mise en œuvre. En combinant les informations de différents types de capteurs, il est possible de tirer parti de leurs forces complémentaires et d'atténuer leurs faiblesses respectives [7].

Dans le contexte de la localisation, la fusion de capteurs peut être réalisée à l'aide de plusieurs méthodes, telles que les filtres de Kalman, les filtres de particules ou les approches d'estimation pondérées. Les filtres EKF et UKF sont particulièrement réputés pour leur capacité à estimer avec efficacité l'état d'un système en présence d'incertitudes et de non-linéarité. Les filtres en question s'appuient sur un modèle d'état, décrivant la dynamique évolutive du système au cours du temps, ainsi qu'un modèle de

mesure, établissant la relation entre les observations des capteurs et l'état du système. Grâce à la mise à jour de l'estimation de l'état à chaque étape de temps en fonction des nouvelles observations des capteurs, les filtres de Kalman se révèlent aptes à fournir une estimation précise de la localisation, même en dépit des bruits et d'incertitude [8].

Dans ce projet, nous proposons d'utiliser la fusion de capteurs pour estimer la localisation d'un véhicule autonome dans une mine souterraine, en combinant les données des capteurs inertiels (IMU) et des valeurs de puissance de signal reçues (RSSI) provenant de balises Bluetooth Low Energy (BLE). Cette approche permet de surmonter les limites des capteurs individuels, tels que les erreurs de dérive des capteurs inertiels et les incertitudes dans les mesures de distance basées sur le RSSI. En utilisant les filtres EKF et UKF pour fusionner les informations provenant de ces capteurs, il est possible d'obtenir une meilleure estimation de la localisation du véhicule autonome, ce qui est essentiel pour améliorer la sécurité et l'efficacité des opérations minières souterraines.

2.2. Matériel et logiciel :

2.2.1. Unité de mesure inertielle (IMU)




Figure 7: Unité de mesure inertielle [9].

Le capteur IMU représenté dans la Figure 7 est un dispositif électronique qui mesure et rapporte les données d'accélération linéaire, de vitesse angulaire et, dans certains cas, de champ magnétique terrestre, en utilisant une combinaison d'accéléromètres, de gyroscopes et de magnétomètres. Ces capteurs sont largement utilisés dans diverses applications, telles que la navigation, la stabilisation, la robotique et les systèmes de contrôle, en raison de leur capacité à fournir des informations précieuses sur la dynamique d'un objet en mouvement.

L'accéléromètre mesure l'accélération linéaire d'un objet le long de trois axes, à savoir les axes x , y et z . Par contre, le gyroscope mesure la vitesse angulaire autour de ces mêmes axes. Le magnétomètre, quant à lui, détecte le champ magnétique terrestre, permettant ainsi de déterminer l'orientation de l'objet par rapport au nord magnétique. La combinaison de ces capteurs permet de fournir des informations exhaustives sur la position, la vitesse et l'orientation de l'objet dans l'espace tridimensionnel. [10].

Afin de déterminer la localisation d'un objet à partir des données d'un capteur IMU, il est nécessaire de procéder à une intégration des données du capteur au fil du temps. L'intégration des mesures d'accélération linéaire permet d'obtenir les vitesses linéaires, tandis que l'intégration des vitesses angulaires permet d'obtenir les angles d'orientation. En intégrant une deuxième fois les vitesses linéaires, il devient envisageable d'estimer la position de l'objet dans l'espace.

Cependant, il est important de noter que les capteurs IMU sont sujets à des erreurs et des incertitudes, telles que le bruit du capteur et les erreurs de dérive. Ces erreurs peuvent s'accumuler au fil du temps, entraînant une dégradation de la précision de la localisation [11]. Afin de remédier à ces problèmes, il est courant de combiner les données de capteurs IMU avec d'autres sources d'information, telles que les balises Bluetooth Low Energy (BLE) ou les systèmes de positionnement global (GPS) [12], en utilisant des techniques de fusion de capteurs, comme les filtres EKF ou UKF [13] [14]. Les spécifications de l'IMU utilisé dans les mesures seront présentées dans la section consacrée au téléphone intelligent utilisé.

En résumé, les capteurs IMU peuvent jouer un rôle de première importance dans la détermination de la localisation des objets en fournissant des informations sur l'accélération, la vitesse angulaire et l'orientation. Toutefois, en raison des erreurs et des incertitudes inhérentes à ces capteurs, il devient souvent impératif de combiner leurs données avec d'autres sources d'information, à l'aide de techniques de fusion de capteurs afin d'obtenir une estimation de localisation plus précise et robuste.

Ci-dessous sont présentés quelques détails techniques supplémentaires sur les capteurs IMU dans le Samsung Galaxy S21 Ultra :

- Gammes de Mesure : Les capteurs IMU du Samsung Galaxy S21 Ultra peuvent avoir différentes gammes de mesure pour l'accéléromètre et le gyroscope. Par exemple, l'accéléromètre peut avoir une gamme de +/- 2g,

+/- 4g ou +/- 16g, permettant de mesurer des accélérations jusqu'à 2g, 4g ou 16g respectivement.

- Précision : La précision des capteurs IMU peut varier en fonction du modèle et du fabricant. Elle est généralement exprimée en pourcentage ou en nombre de bits. Une précision plus élevée signifie que le capteur fournit des mesures plus précises et moins sujettes à des erreurs.
- Taux d'Échantillonnage : Le taux d'échantillonnage des capteurs IMU du Galaxy S21 Ultra indique à quelle fréquence ils mesurent et rapportent les données. Un taux d'échantillonnage plus élevé permet d'obtenir des mises à jour plus fréquentes des mesures, ce qui est important pour les applications nécessitant une réponse en temps réel.
- Consommation d'Énergie : Les capteurs IMU du Galaxy S21 Ultra sont conçus pour être économes en énergie, en particulier dans les smartphones et autres appareils mobiles, pour préserver l'autonomie de la batterie.
- Résolution : La résolution des capteurs IMU du Galaxy S21 Ultra détermine le plus petit changement détectable dans la mesure. Une résolution plus élevée permet d'obtenir des mesures plus fines et plus détaillées.
- Interface de Communication : Les capteurs IMU du Galaxy S21 Ultra peuvent utiliser différentes interfaces de communication pour transmettre les données aux processeurs ou aux microcontrôleurs, telles que I2C (Inter-Integrated Circuit), SPI (Serial Peripheral Interface) ou UART (Universal Asynchronous Receiver/Transmitter).
- Température de Fonctionnement : Les capteurs IMU du Galaxy S21 Ultra sont conçus pour fonctionner dans une plage de température spécifique. Il est important de connaître la température de fonctionnement du capteur, surtout dans les environnements extrêmes.

- Taille et Forme : Les capteurs IMU du Galaxy S21 Ultra sont généralement compacts et intégrés dans des puces ou des modules. Leur taille et leur forme sont optimisées pour être intégrées dans des appareils tels que les smartphones, les drones, les montres intelligentes, etc.
- Stabilité à Long Terme : Les capteurs IMU du Galaxy S21 Ultra sont conçus pour avoir une stabilité à long terme, réduisant ainsi les erreurs de dérive au fil du temps.
- Capacités Avancées : Les capteurs IMU du Galaxy S21 Ultra peuvent inclure des fonctionnalités supplémentaires avancées, telles que la détection de gestes, la reconnaissance d'activités, la détection d'orientation relative, etc. Ces fonctionnalités ajoutent des possibilités supplémentaires d'utilisation et d'interaction avec l'appareil.

2.2.2. Bluetooth à Basse Consommation (BLE):

La technologie Bluetooth Low Energy (BLE), connue également sous le nom de Bluetooth Smart, est une version économe en énergie de la norme Bluetooth développée spécifiquement pour les applications de communication sans fil à courte portée. Les balises BLE, illustrées dans la Figure 8, sont de petits dispositifs émetteurs qui exploitent cette technologie pour envoyer des signaux radio en continu. Ces signaux peuvent être détectés et interprétés par des dispositifs compatibles, tels que des smartphones ou des récepteurs dédiés, pour fournir diverses fonctionnalités, telles que la localisation en intérieur et le suivi d'objets [15].



Figure 8: Un assortiment d'iBeacons de différents fournisseurs.

Dans les environnements intérieurs ou souterrains, caractérisés par une réception GPS souvent peu fiable ou indisponible en raison de la faible disponibilité du signal satellite, l'utilisation des balises BLE se présente comme une alternative pour déterminer la localisation des objets. Cela est possible grâce à la mesure de la puissance du signal reçu (RSSI, Received Signal Strength Indicator) des balises par les dispositifs récepteurs. En ayant connaissance de la puissance du signal émis par les balises et de la puissance du signal reçu, il devient possible de calculer la distance entre le dispositif récepteur et les balises, en recourant à un modèle de propagation du signal tel que le modèle de propagation en espace libre ou le modèle log-normal.

Lorsqu'il y a suffisamment de balises, comprenant au moins trois balises ayant des positions géographiques bien définies, et que les distances entre le dispositif récepteur et ces balises ont été calculées, la technique de trilatération peut être utilisée pour estimer la position du dispositif récepteur [16]. La trilatération, en tant que procédé mathématique, permet de déterminer la position d'un point donné en utilisant les distances entre ce point et d'autres points de référence, dont les positions sont préalablement connues [17].

Cependant, les estimations de localisation basées sur les balises BLE peuvent être affectées par des facteurs environnementaux, tels que les interférences radio, les obstacles physiques et les réflexions du signal. Pour améliorer la précision de la localisation, il est courant de combiner les données des balises BLE avec d'autres sources d'information, telles que les capteurs inertiels (IMU) ou les systèmes de positionnement global (GPS), en utilisant des techniques de fusion de capteurs, comme les filtres de Kalman EKF ou UKF.

Dans le cadre de ce projet, le module HM-18/HM-19 CC2640R2 a été adopté en tant que balise BLE. Les paramètres de ces balises sont les suivants :

- Version BT : Spécification Bluetooth V4.2 / 5.0 BLE.
- Aucune limite d'octets en envoi ou réception.
- Fréquence de fonctionnement : bande ISM 2,4 GHz.
- Méthode de modulation : GFSK (Gaussian Frequency Shift Keying).
- Puissance RF : -18 dbm ~ 3 dbm.
- Vitesse : Asynchrone : 3-8K octets.
- Alimentation : +1,9 ~ 3,7 VDC 50mA.
- Consommation électrique : mode veille 2,6 mA, mode actif 2,6 mA.

En résumé, la technologie BLE et les balises représente une solution prometteuse pour la détermination de la localisation des objets dans des environnements intérieurs ou souterrains en fournissant des informations sur la distance entre les dispositifs récepteurs et les balises, et en utilisant la technique de trilatération pour estimer la position. Cependant, pour parvenir à une estimation de localisation plus précise et robuste, il est impératif de procéder à la combinaison des données issues des balises BLE avec celles provenant d'autres sources d'information, en utilisant des techniques de fusion de capteurs avancées.

2.2.3. MATLAB :

MATLAB (MATrix LABoratory) est un environnement de programmation et de calcul numérique développé par MathWorks. Il est largement utilisé par les chercheurs, les ingénieurs et les scientifiques pour résoudre des problèmes complexes dans divers domaines, tels que les mathématiques, la physique, la biologie et l'ingénierie. MATLAB offre un langage de programmation facile à utiliser et des bibliothèques de fonctions pour le traitement du signal, l'optimisation, l'algèbre linéaire, la statistique et bien d'autres domaines [18].

Dans le contexte de la détermination de la localisation d'objets en intérieur ou souterrain, MATLAB s'avère pertinente pour implémenter et analyser des algorithmes de localisation, tels que les filtres de Kalman EKF et UKF [19]. Ces filtres, considérés comme des techniques de fusion de capteurs avancées, permettent d'estimer avec précision l'état d'un système (tel que la position et la vitesse d'un objet) en traitant les données bruitées et incertaines provenant de sources diverses, telles que les capteurs inertiels (IMU) et les balises Bluetooth Low Energy (BLE) [20].

En utilisant MATLAB, vous pouvez :

1. Charger et prétraiter les données collectées à partir des capteurs et des balises.
2. Implémenter les modèles de propagation du signal pour calculer les distances entre les dispositifs récepteurs et les balises.
3. Appliquer la trilatération pour estimer la position à partir des distances calculées.
4. Implémenter et comparer les performances des filtres EKF et UKF pour fusionner les données des capteurs IMU et des balises BLE afin d'obtenir une estimation de localisation plus précise et robuste.

5. Visualiser et analyser les résultats obtenus, tels que les trajectoires estimées et les erreurs de localisation, pour évaluer la qualité des algorithmes de localisation et identifier les améliorations possibles.

MATLAB offre une gamme variée de boîtes à outils supplémentaires, telles que la boîte à outils de traitement du signal, la boîte à outils de systèmes de contrôle et la boîte à outils de robotique, qui se révèlent être des aides à implémenter et à optimiser les algorithmes de localisation et de fusion de capteurs. En résumé, MATLAB est un outil puissant et flexible, capable de faciliter l'implémentation, l'analyse et l'évaluation des algorithmes de localisation en environnements intérieurs et souterrains, en tirant parti des techniques de fusion de capteurs telles que les filtres EKF et UKF.

2.2.4. Téléphone Intelligent:

Le Samsung Galaxy S21 Ultra représente un smartphone haut de gamme, doté d'un éventail étendu de fonctionnalités et de capteurs. Il a été utilisé pour mesurer le RSSI des balises BLE environnantes et pour collecter des données à partir de ses capteurs inertiels intégrés (IMU), tels que l'accéléromètre, le gyroscope et le magnétomètre.

Afin de mesurer le RSSI des balises BLE, l'application "Thingsup BLE Scanner" a été mise à profit. Cette application s'avère être un outil adéquat pour détecter et afficher les balises BLE à proximité et de fournir des informations telles que l'adresse MAC, le nom, la puissance du signal reçu (RSSI) et d'autres données spécifiques aux balises. Le Samsung Galaxy S21 Ultra, quant à lui, est équipé de la technologie Bluetooth 5.0, qui offre une portée accrue, une vitesse de transfert de données plus élevée et une consommation d'énergie réduite par rapport aux versions précédentes de Bluetooth.

Dans le but de collecter les données de l'accéléromètre, du gyroscope et du magnétomètre intégrés dans le Samsung Galaxy S21 Ultra, l'application "phyphox" a été utilisée. Phyphox est une application qui permet d'accéder aux capteurs du smartphone et de collecter, analyser et visualiser les données en temps réel ou de les exporter pour une analyse ultérieure. Les spécifications des capteurs IMU intégrés dans le Samsung Galaxy S21 Ultra sont répertoriées ci-dessous, et les caractéristiques détaillées sont présentées dans le Tableau I [21].

- Accéléromètre : Il mesure l'accélération linéaire du smartphone dans les trois axes (x, y, z) et peut être utilisé pour estimer la position et la vitesse de l'appareil en intégrant les données d'accélération deux fois.
- Gyroscope : Il mesure la vitesse angulaire du smartphone autour des trois axes (x, y, z) et peut être utilisé pour estimer l'orientation de l'appareil en intégrant les données de vitesse angulaire.
- Magnétomètre : Il mesure le champ magnétique terrestre dans les trois axes (x, y, z) et peut être utilisé pour déterminer l'orientation de l'appareil par rapport au nord magnétique, en fournissant une référence pour le cap.

Tableau I: Caractéristiques des capteurs du téléphone utilisé.

Nom	Modèle	Plage de mesure	Résolution	Fréquence d'échantillonnage	Interface de communication
Accéléromètre	LSM6DSL	±2 g ±4 g ±8 g ±16 g	16 bits	Jusqu'à 6.66 KHz	SPI / I2C
Gyroscope	LSM6DSL	±125 dps ±245 dps ±500 dps ±1000 dps ±2000 dps	16 bits	Jusqu'à 1.66 KHz	SPI / I2C
Magnétomètre	AK09918	±4900 μ T	0,15 μ T par LSB	Jusqu'à 100 KHz	I2C

CHAPITRE 3

ARCHITECTURE DE FUSION DE CAPTEURS :

Dans cette section, nous procéderons à un aperçu des fondements mathématiques et des calculs impliqués dans l'application des filtres EKF et UKF pour la fusion de capteurs dans notre système de localisation. Par ailleurs, nous aborderons l'intégration de l'estimation du coefficient d'environnement 'n' dans le processus de filtrage, permettant au système de s'adapter automatiquement aux différentes conditions environnementales.

Les filtres EKF et UKF sont des techniques puissantes d'estimation d'état, conçues pour gérer les dynamiques et les modèles de mesure non linéaires d'un système. Leur utilisation s'étend à une variété d'applications, dont la fusion de capteurs et la localisation, où ils permettent de combiner les données provenant de multiples sources afin d'obtenir des estimations d'état du système à la fois plus précises et fiables [22].

Le filtre EKF, une extension du filtre de Kalman linéaire classique, a été spécifiquement conçu pour prendre en charge les dynamiques et les modèles de mesure non linéaires grâce à la linéarisation. Par la suite, l'EKF se sert de ces modèles linéarisés pour mettre à jour l'estimation de l'état et la matrice de covariance.

En revanche, le filtre UKF aborde les non-linéarités en utilisant une approche d'échantillonnage déterministe appelée Transformation non linéaire. L'UKF génère un ensemble de points sigma, qui représentent la moyenne et la covariance de l'état, et propage ces points sigma à travers les fonctions non linéaires. L'estimation de l'état actualisée et la matrice de covariance sont ensuite calculées en utilisant les points sigma ainsi transformés.

Dans le cadre de notre système, nous avons étendu le vecteur d'état pour inclure le coefficient d'environnement 'n' ainsi que les estimations de localisation et de vitesse. Cette extension permet aux filtres EKF et UKF d'estimer automatiquement le coefficient d'environnement, et ainsi de s'adapter de manière adaptative aux conditions changeantes de l'environnement souterrain. En intégrant cette fonctionnalité adaptative, le système gagne en robustesse et est en mesure de fournir des estimations de localisation plus précises dans différents scénarios [23].

Durant cette section, nous procéderons à une analyse approfondie des calculs et des algorithmes requis pour mettre en œuvre l'EKF et l'UKF au sein de notre système de fusion de capteurs. Nous mettrons en évidence la manière dont ces filtres sont utilisés pour estimer non seulement la localisation et la vitesse, mais également le coefficient d'environnement 'n'. De surcroît, nous aborderons les avantages et les limites de chaque approche de filtrage, et nous fournirons des données sur leur performance dans le contexte de notre application spécifique [24].

3.1. Trilatération:

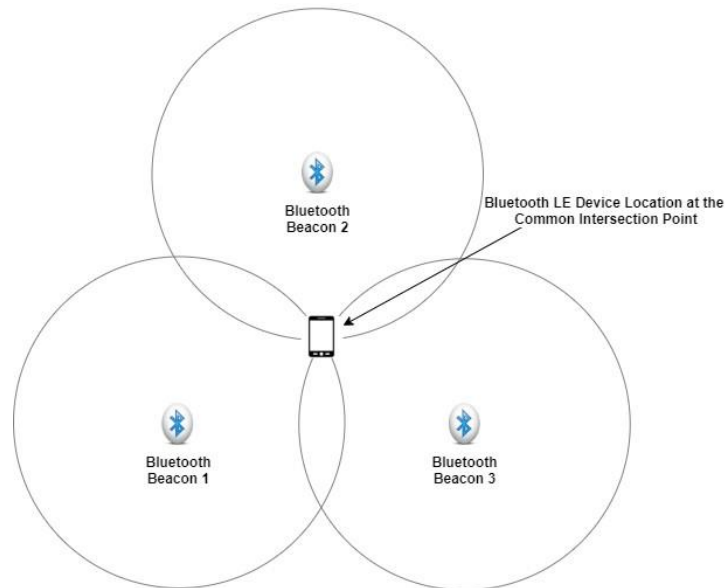


Figure 9: Méthode de Trilatération.

La trilatération, présentée dans la Figure 9, se présente comme une méthode utilisée pour déterminer la position d'un objet en calculant les distances entre cet objet et trois points de référence. Dans notre cas, ces points de référence correspondent aux balises BLE, et la position de l'objet est évaluée en se basant sur les valeurs RSSI mesurées par le téléphone. Afin de réaliser cette évaluation, la première étape consiste à convertir les valeurs RSSI en distances [25]. Pour ce faire, on utilise la formule suivante :

$$D = 10^{\left(\frac{TX - IRSSI}{10^n}\right)} \quad (1)$$

- D : distance entre la balise BLE et le scanner (m)
- TX : valeur du RSSI à 1 m (dBm)
- IRSSI : le RSSI mesurée (dBm)
- n : le coefficient environnemental

Ensuite, on a besoin des coordonnées (x, y) des trois balises BLE (B1, B2, B3) :

$$B1 : (x_1, y_1), B2 : (x_2, y_2), B3 : (x_3, y_3)$$

À partir des distances calculées dans la première étape (d_1, d_2, d_3) qui sont les distances entre chaque balise BLE et la véhicules, on peut établir le système d'équations suivant :

$$\begin{cases} (x - x_1)^2 + (y - y_1)^2 = d_1^2 \\ (x - x_2)^2 + (y - y_2)^2 = d_2^2 \\ (x - x_3)^2 + (y - y_3)^2 = d_3^2 \end{cases} \quad (2)$$

Pour résoudre ce système d'équations et trouver les coordonnées (x, y) du téléphone, on soustrait la première équation de la deuxième et la deuxième de la troisième :

$$2(x_2 - x_1)x + 2(y_2 - y_1)y = d_1^2 - d_2^2 + x_2^2 - x_1^2 + y_2^2 - y_1^2 \quad (3)$$

$$2(x_3 - x_2)x + 2(y_3 - y_2)y = d_2^2 - d_3^2 + x_3^2 - x_2^2 + y_3^2 - y_2^2 \quad (4)$$

À ce stade, on obtient un système de deux équations linéaires à deux inconnues (x, y) . On peut résoudre ce système en utilisant, par exemple, la méthode de substitution ou la méthode du déterminant. Une fois les coordonnées (x, y) du téléphone obtenu, on peut les utiliser pour estimer la position du véhicule autonome dans la mine souterraine [26].

En résumé, la trilatération consiste à convertir les valeurs RSSI en distances, établir un système d'équations à partir des coordonnées des balises BLE et des distances, puis résoudre ce système pour obtenir la position de l'objet [27].

3.2. *Extended Kalman Filter (EKF):*

Le Extended Kalman Filter (EKF) est la disposition non linéaire du filtre Kalman. La plupart des problèmes du monde réel impliquent des fonctions non linéaires. Dans la plupart des cas, le système examine une direction et prend des mesures dans une autre direction. Cela implique des fonctions d'angles et de sinus, de cosinus qui sont des fonctions non linéaires. Ici, nous utiliserons série de Taylor, comme illustrée dans l'équation (5), pour obtenir une approximation linéaire de la fonction non linéaire. Une fois cette approximation appliquée, nous obtenons le filtre de Kalman étendu (EKF).

Dans la série de Taylor nous prenons un point et effectuons un tas de dérivés sur ce point. De manière similaire, dans le cas de l'Extended Kalman Filter (EKF), nous prenons la moyenne du gaussien sur la courbe non linéaire et effectuons un certain nombre de dérivés pour l'approcher.

$$f(a) + \frac{f'(a)}{1!}(x - a) + \frac{f''(a)}{2!}(x - a)^2 + \frac{f'''(a)}{3!}(x - a)^3 + .. \quad (5)$$

Notre intérêt se porte principalement sur la linéarisation, donc nous nous concentrons exclusivement sur le premier dérivé de la série de Taylor. Pour chaque fonction non linéaire, il suffit de tracer une tangente autour de la moyenne et d'essayer d'approcher la fonction linéairement comme le montre la Figure 10. Dans le monde réel, nous sommes souvent confrontés à des fonctions non linéaires qui perturbent nos Gaussiennes, c'est pourquoi nous cherchons à les approximer linéairement en utilisant la série de Taylor, ce qui aboutit à l'approche EKF.

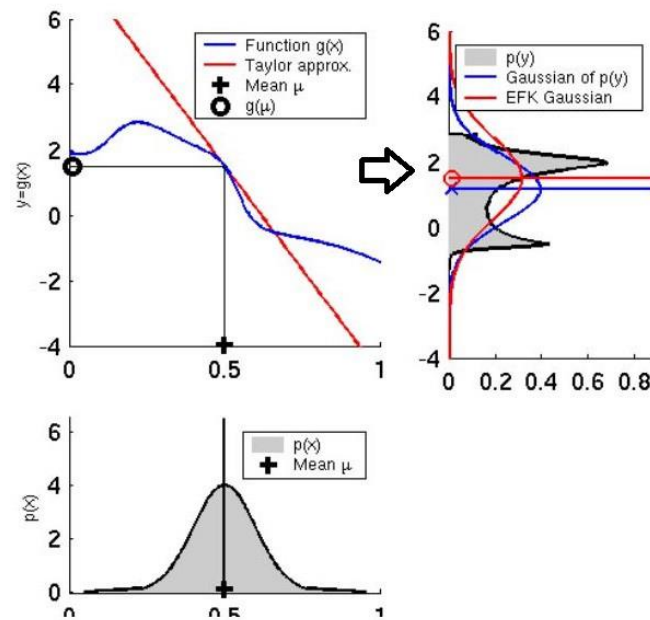


Figure 10: Scénario Après Application de L'Approximation de Taylor à la Linéarisation d'une Fonction.

Dans la série de Taylor nous prenons un point et effectuons un tas de dérivés sur ce point. Dans le cas d'un EKF, nous prenons la moyenne du gaussien sur la courbe non linéaire et effectuons un certain nombre de dérivés pour l'approcher [28].

3.2.1. Étape de prédiction :

$$x' = F * x + B * \mu + v \quad (6)$$

- x' : Valeur prédite
- F : Matrice de transition d'état
- B : Matrice d'entrée de contrôle
- μ : Vecteur de contrôle
- v : Bruit de système

F est une matrice de transition d'état ou une matrice adaptable qui sont nécessaires pour convertir la matrice d'un formulaire à l'autre. Par exemple, disons que nous avons un modèle où nous prédisons la position et la vitesse de l'objet qui n'accélère pas. Dans ce cas, le nouveau p et v après un delta de temps t est donné comme :

$$p' = p + v\Delta t \quad (7)$$

$$v' = v \quad (8)$$

B est la matrice d'entrée de contrôle qui indique le changement d'état de l'objet dû à une force interne ou externe. Par exemple, la force de gravité ou la force de frottement à l'objet.

v est le bruit dans le processus. Nous ajoutons le bruit aléatoire qui pourrait être présent dans le canal pour rendre notre prédiction un peu correcte.

$$P' = FPF^T + Q \quad (9)$$

- P' : Covariance prévue
- F^T : Transposition de la matrice de transition d'état
- Q : Bruit

Pour la matrice Q, nous supposons que l'objet a changé de direction ou peut-être accéléré ou décéléré. Donc après un certain temps Δt , notre incertitude augmente d'un facteur de Q qui est encore le bruit. Alors, nous ajoutons le bruit au bruit techniquement. Dans l'étape de prédiction, nous obtenons les deux valeurs prédites x' et P' .

3.2.2. Étape de mise à jour :

$$y = z - h(x') \quad (10)$$

- z : Mesure réelle en coordonnées polaires
- h : Fonction qui spécifie comment notre vitesse et notre position sont mappées aux coordonnées polaires
- x' : Valeur prédite
- y : Différence entre la valeur mesurée et la valeur réelle

$h(x')$ est une fonction qui spécifie la cartographie entre nos valeurs prédites en coordonnées cartésiennes et les coordonnées polaires.

$$S = H_j P' H_j^T + R \quad (11)$$

$$K = P' H_j^T S^{-1} \quad (12)$$

- R : Bruit de mesure
- K : Gain de Kalman
- S : Erreur totale
- S^{-1} : L'inverse de S
- H_j : La matrice jacobienne

$$x = x' + K * y \quad (13)$$

$$P = (I - KH_j)P' \quad (14)$$

Dans la dernière étape, nous mettons à jour nos x et P selon les calculs effectués par le gain Kalman.

3.2.3. Application de EKF dans mon système :

1. Étendre le vecteur d'état pour inclure la localisation (x, y), la vitesse (vx, vy) et le coefficient d'environnement 'n' :

$$X = [x, y, vx, vy, n]^T \quad (15)$$

2. Définir les modèles de dynamique du système (fonction de transition d'état) et les modèles de mesure (fonction de mesure). Utilisez les données de l'accéléromètre et du gyroscope pour estimer la localisation et la vitesse. Pour les valeurs de RSSI, utilisez également la trilatération pour estimer la localisation. Le modèle de mesure du RSSI est donné par :

$$RSSI = RSSI_0 - 10 * n * \log_{10}(d) \quad (16)$$

3. Initialiser l'estimation de l'état et la matrice de covariance :

$$X_0 = [x_{init}, y_{init}, vx_{init}, vy_{init}, n_{init}]^T \quad (17)$$

$$P_0 = \text{diag}([var_x, var_y, var_{vx}, var_{vy}, var_n]) \quad (18)$$

4. À chaque pas de temps, mettez à jour l'estimation de l'état et la matrice de covariance en utilisant les mesures des capteurs :

- a) Prédiction de l'état et de la matrice de covariance :

$$X_{pred} = f(X, u, dt) \quad (19)$$

Où f est la fonction de transition d'état, u est le vecteur de commande (accélération et rotation provenant des capteurs IMU) et dt est l'intervalle de temps.

$$P_{pred} = F * P * F^T + Q \quad (20)$$

Où F est la matrice Jacobienne de la fonction de transition d'état, et Q est la matrice de covariance du bruit du processus.

- b) Mise à jour de l'estimation de l'état et de la matrice de covariance en utilisant les mesures :

$$y = z - h(X_{pred}) \quad (21)$$

Où z est le vecteur de mesure (RSSI et éventuellement localisation par trilatération), et h est la fonction de mesure.

$$S = H * P_{pred} * H^T + R \quad (22)$$

Où H est la matrice Jacobienne de la fonction de mesure, et R est la matrice de covariance du bruit de mesure.

$$K = P_{pred} * H^T * S^{-1} \quad (23)$$

Où K est le gain de Kalman.

$$X = X_{pred} + K * y \quad (24)$$

Où X est l'estimation de l'état mise à jour.

$$P = (I - K * H) * P_{pred} \quad (25)$$

Où P est la matrice de covariance mise à jour et I est la matrice identité.

5. Répéter les étapes 4a et 4b pour chaque nouvelle mesure.

Tout ça peut être résumé par le schéma dans la Figure 11, et les équations simplifier dans la Figure 12.

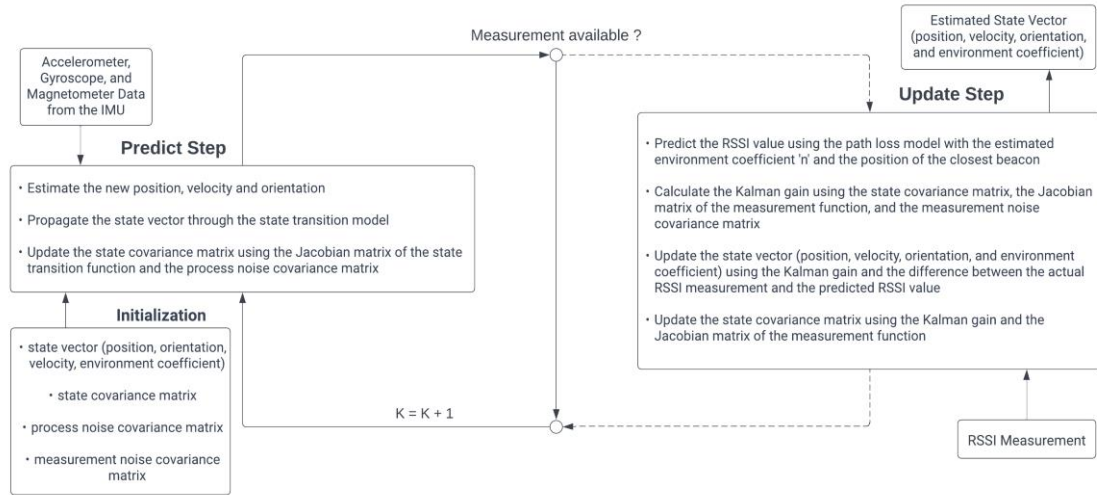


Figure 11: Schéma qui montre l'algorithme du EKF.

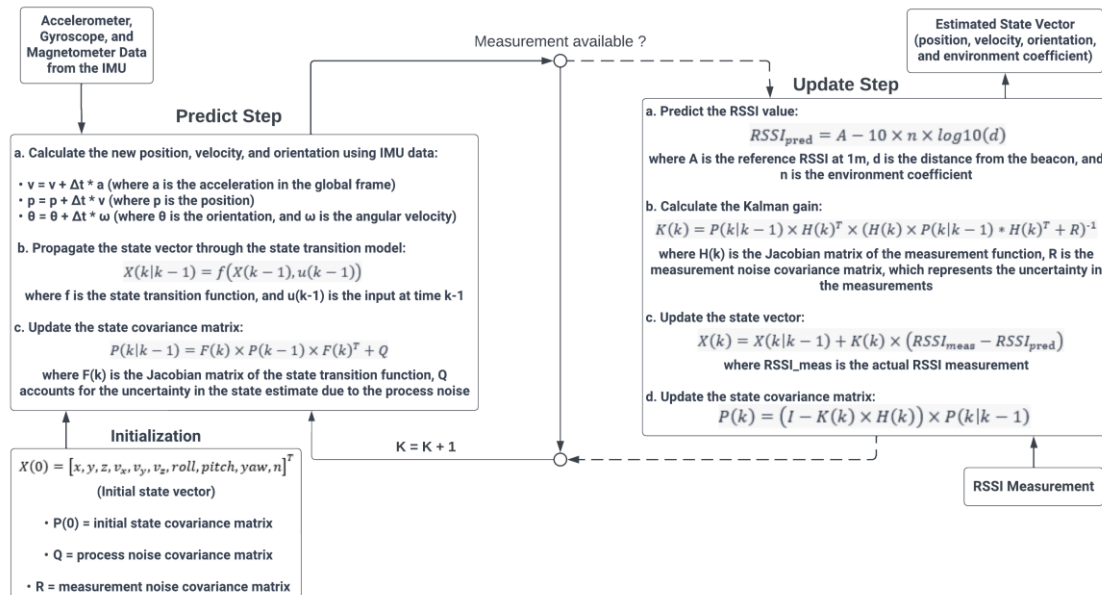


Figure 12: Schéma qui montre l'algorithme du EKF avec les équations.

La liste des variables utilisé :

- $X(0)$: Vecteur d'état initial qui comprend la position (x, y, z) , la vitesse (v_x, v_y, v_z) , l'orientation (roulis, tangage, lacet) et le coefficient d'environnement (n) .
- $P(0)$: Matrice de covariance d'état initiale qui représente l'incertitude du vecteur d'état initial.
- Q : Matrice de covariance de bruit de processus qui modélise l'incertitude dans la fonction de transition d'état.
- R : Matrice de covariance de bruit de mesure qui modélise l'incertitude dans la fonction de mesure.
- v : Vecteur de vitesse qui est mis à jour en utilisant les données IMU.
- p : Vecteur de position qui est mis à jour en utilisant le vecteur de vitesse et les données IMU.
- θ : Vecteur d'orientation qui est mis à jour en utilisant la vitesse angulaire et les données IMU.
- a : Vecteur d'accélération dans le référentiel global qui est obtenu à partir des données IMU.
- $X(k|k-1)$: Moyenne d'état prédite qui est obtenue en propageant le vecteur d'état à travers la fonction de transition d'état.
- f : Fonction de transition d'état qui associe l'état actuel et l'entrée à l'état suivant.
- $u(k-1)$: Entrée au temps $k-1$.
- $P(k|k-1)$: Matrice de covariance d'état prédite qui représente l'incertitude de la moyenne d'état prédite.
- $F(k)$: Matrice jacobienne de la fonction de transition d'état qui représente les dérivées partielles de la fonction de transition d'état par rapport aux variables d'état.

- A : RSSI de référence à 1m.
- d : Distance du balise.
- n : Coefficient d'environnement qui affecte la valeur RSSI.
- $RSSI_{pred}$: Valeur RSSI prédite qui est calculée en utilisant la distance de la balise et le coefficient d'environnement.
- $K(k)$: Gain de Kalman qui détermine la contribution de la mesure à l'état et à la covariance mise à jour.
- $H(k)$: Matrice jacobienne de la fonction de mesure qui représente les dérivées partielles de la fonction de mesure par rapport aux variables d'état.
- $RSSI_{meas}$: Mesure RSSI réelle qui est utilisée pour mettre à jour le vecteur d'état.
- $X(k)$: Moyenne d'état mise à jour qui est obtenue en ajoutant le produit du gain de Kalman et de la différence entre la mesure RSSI réelle et la valeur RSSI prédite à la moyenne d'état prédite.
- $P(k)$: Matrice de covariance d'état mise à jour qui représente l'incertitude de la moyenne d'état mise à jour.

3.3. *Unscented Kalman Filter (UKF):*

Dans l'EKF, nous nous contentons d'un seul point pour estimer le Gaussien, ce qui permet une linéarisation plus simple. Cependant, il existe une méthode plus avancée pour passer d'une distribution gaussienne source à une approximation gaussienne en utilisant un ensemble de points, y compris la moyenne, et en réalisant une approche raffinée à partir de ces multiples points. Il serait inefficace de considérer tous les points de la source gaussienne, puis de les transformer et enfin de réaliser une approximation, car cela demanderait une grande puissance de calcul et de ressources. Ainsi, bien que l'approche à un seul point soit la solution la plus simple, elle n'est pas optimale [13].

Dans UKF, nous avons un concept de points Sigma. Nous prenons quelques points sur la source gaussienne et les cartographions sur la cible gaussienne après avoir passé des points à travers une fonction non linéaire, puis nous calculons la nouvelle moyenne et variance de gaussien transformé. Transformer l'intégralité de la distribution d'état par une fonction non linéaire peut s'avérer très difficile, mais il est bien plus aisé de transformer des points individuels de cette distribution d'état. Ces points, que nous appelons points Sigma, servent de représentants de l'ensemble de la distribution [29].

En complément des points sigma, chaque point sigma possède également un poids, ce qui en fait des points sigma pondérés. Ces poids permettent de donner plus ou moins d'importance à certains points afin d'améliorer notre approximation. Lorsqu'un Gaussien est soumis à une fonction non linéaire, il n'est plus représenté par un autre Gaussien, mais nous approchons le Gaussien à partir de la figure résultante. Ainsi, dans l'Unscented Kalman Filter (UKF), un processus appelé "Unscented Transform" nous aide à accomplir cette tâche de manière plus précise [30].

Pour résumer, voici les étapes que la transformation non parfumée effectue :

1. Calculer l'ensemble de points Sigma.
2. Attribuer des poids à chaque point sigma.
3. Transformer les points par une fonction non linéaire.
4. Calculer le gaussien à partir de points pondérés et transformés.
5. Calculer la moyenne et la variance du nouveau gaussien.

Le nombre de points sigma dépend de la dimensionnalité du système. La formule générale est $2N + 1$, où N indique les dimensions.

$$\begin{cases} X^{[0]} = \mu \\ X^{[i]} = \mu + \left(\sqrt{(n + \lambda)\Sigma}\right)_i & \text{for } i = 1, \dots, n \\ X^{[i]} = \mu - \left(\sqrt{(n + \lambda)\Sigma}\right)_{i-n} & \text{for } i = n + 1, \dots, 2n \end{cases} \quad (26)$$

- X : Matrice des points Sigma
- μ : Moyenne gaussienne
- n : dimensionnalité du système
- λ : Facteur d'échelle
- Σ : matrice de covariance

Chaque colonne de X indique un ensemble de points sigma. λ est le facteur d'échelle qui indique à quelle distance nous devrions choisir nos points sigma. Évidemment, l'un des points sigma est la moyenne, et le reste nous calculons sur la base d'équations (26).

Calcul des poids des points Sigma :

$$\begin{cases} \omega^{[0]} = \frac{\lambda}{n+\lambda} \\ \omega^{[i]} = \frac{1}{2(n+\lambda)} \end{cases} \quad \text{for } i = 1, \dots, 2n \quad (27)$$

Le calcul du poids de la moyenne a une équation différente du reste des points sigma. λ est le paramètre d'étalement et n est la dimensionnalité. Il est intéressant de noter ici que la somme de tous les poids est égale à 1.

Calcul de la moyenne et de la covariance du gaussien approximatif :

$$\begin{cases} \mu' = \sum_{i=0}^{2n} \omega^{[i]} g(X^{[i]}) \\ \Sigma' = \sum_{i=0}^{2n} \omega^{[i]} (g(X^{[i]}) - \mu')(g(X^{[i]}) - \mu')^T \end{cases} \quad (28)$$

- μ' : Moyenne prévue
- Σ' : Covariance prévue
- w : Poids des points sigma
- g : Fonction non linéaire
- X : Matrice des points Sigma
- n : Dimension

3.3.1. Étape de prédiction :

1. Calculer les points Sigma à l'aide des équations (26).
2. Calculer les poids des points Sigma à l'aide des équations (27).
3. Transformer les points Sigma et calculer une nouvelle moyenne et covariance- Il est très proche des équations (28). Chaque fois que nous prédisons, notre incertitude augmente d'une certaine quantité, parce que nous devenons un peu incertains donc nous devons tenir compte du bruit de processus.

$$\begin{cases} \mu' = \sum_{i=0}^{2n} \omega^{[i]} g(X^{[i]}) \\ \Sigma' = \sum_{i=0}^{2n} \omega^{[i]} (g(X^{[i]}) - \mu')(g(X^{[i]}) - \mu')^T + R_t \end{cases} \quad (29)$$

3.5.1. Étape de mise à jour :

Dans l'étape de mise à jour, nous avons une mesure provenant du capteur. Pour calculer la différence entre nos valeurs prévues de moyenne et de covariance et les valeurs réelles de moyenne et de covariance, nous prenons notre état prévu à l'état de mesure. Nous prenons notre état de notre espace d'état à l'espace d'état de mesure.

$$\begin{cases} Z = h(X) \\ \hat{Z} = \sum_{i=0}^{2n} \omega^{[i]} Z^{[i]} \\ S = \sum_{i=0}^{2n} \omega^{[i]} (Z^{[i]} - \hat{Z})(Z^{[i]} - \hat{Z})^T + Q \end{cases} \quad (30)$$

- Z : Points sigma transformés dans l'espace de mesure c'est-à-dire la mesure qui provient du capteur
- X : Matrice des points Sigma
- \hat{Z} : Moyenne de l'espace de mesure
- S : Covariance dans l'espace de mesure

- Q : Bruit
- h : Est une fonction qui mappe nos points sigma à l'espace de mesure

Pour calculer l'erreur de prédiction : Nous devons calculer la corrélation croisée entre les points sigma dans l'espace d'état et les points sigma dans l'espace de mesure.

$$\begin{cases} T = \sum_{i=0}^{2n} \omega^{[i]} (X^{[i]} - \mu') (Z^{[i]} - \hat{Z})^T \\ K = T \cdot S^{-1} \end{cases} \quad (31)$$

- T : Matrice de co-relation croisée entre l'espace d'état et l'espace prévu
- S : Matrice de covariance prévue
- K : Gain de Kalman

$$\begin{cases} \mu = \mu' + K(Z - \hat{Z}) \\ \Sigma = (I - KT)\Sigma' \end{cases} \quad (32)$$

- μ : Moyenne
- Σ : Covariance
- μ' : Moyenne prévue
- Σ' : Covariance prévue
- K : Gain de Kalman
- z : Moyenne de mesure réelle provenant du capteur
- \hat{z} : Moyenne de l'espace de mesure
- T : Il est le même que H dans Kalman Filter et H_j dans EKF. Ici, il est matrice de co-relation croisée

3.5.1. Application de UKF dans mon système :

1. Étendre le vecteur d'état et initialiser l'estimation de l'état et la matrice de covariance, comme pour l'EKF :

$$X = [x, y, vx, vy, n]^T \quad (33)$$

$$X_0 = [x_{init}, y_{init}, vx_{init}, vy_{init}, n_{init}]^T \quad (34)$$

$$P_0 = \text{diag}([var_x, var_y, var_{vx}, var_{vy}, var_n]) \quad (35)$$

2. Définir les modèles de dynamique du système et les modèles de mesure, comme pour l'EKF.
3. Choisir les paramètres du UKF, tels que alpha, beta et kappa, qui déterminent la distribution des points de sigma et la matrice de covariance.
4. À chaque pas de temps, mettez à jour l'estimation de l'état et la matrice de covariance en utilisant les mesures des capteurs :
 - a) Génération des points de sigma en fonction de l'estimation de l'état et de la matrice de covariance :

$$X_{sigma} = [X, X + L, X - L] \quad (36)$$

Où L est la matrice de Cholesky de la matrice de covariance $P(L^T * L = P)$.

- b) Prédiction de l'état et de la matrice de covariance :

$$X_{sigma-pred} = f(X_{sigma}, u, dt) \quad (37)$$

Où f est la fonction de transition d'état non linéaire, u est le vecteur de commande et dt est l'intervalle de temps.

$$X_{pred} = \text{somme des poids des points de sigma multipliés par } X_{sigma-pred}.$$

$P_{pred} =$ somme des poids des points de sigma multipliés par $(X_{sigma-pred} - X_{pred})(X_{sigma-pred} - X_{pred})^T + Q$.

- c) Mise à jour de l'estimation de l'état et de la matrice de covariance en utilisant les mesures :

$$Z_{sigma} = h(X_{sigma-pred}) \quad (38)$$

Où h est la fonction de mesure non linéaire.

$Z_{pred} =$ somme des poids des points de sigma multipliés par Z_{sigma} .

$P_{zz} =$ somme des poids des points de sigma multipliés par $(Z_{sigma} - Z_{pred})(Z_{sigma} - Z_{pred})^T + R$.

$P_{xz} =$ somme des poids des points de sigma multipliés par $(X_{sigma-pred} - X_{pred})(Z_{sigma} - Z_{pred})^T$.

$$K = P_{xz} * P_{zz}^{-1} \quad (39)$$

Où K est le gain de Kalman.

$$X = X_{pred} + K * (z - Z_{pred}) \quad (40)$$

Où z est le vecteur de mesure et X est l'estimation de l'état mise à jour.

$$P = P_{pred} - K * P_{zz} * K^T \quad (41)$$

Où P est la matrice de covariance mise à jour.

5. Répéter les étapes 4a, 4b et 4c pour chaque nouvelle mesure.

Tout ça peut être résumé par le schéma dans la Figure 13, et les équations simplifier dans la Figure 14.

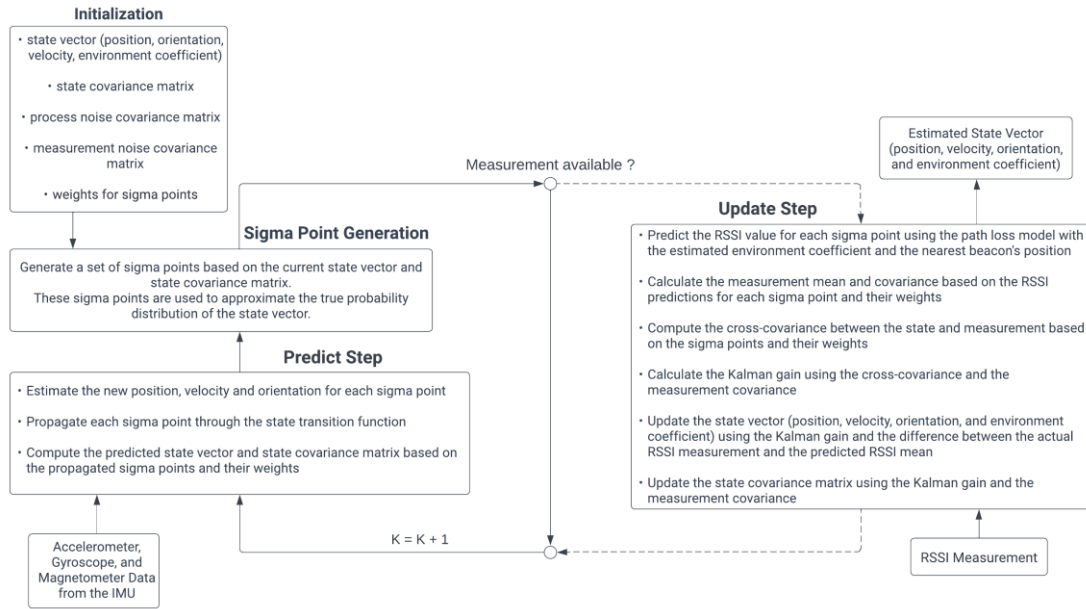


Figure 13: Schéma qui montre l'algorithme du UKF.

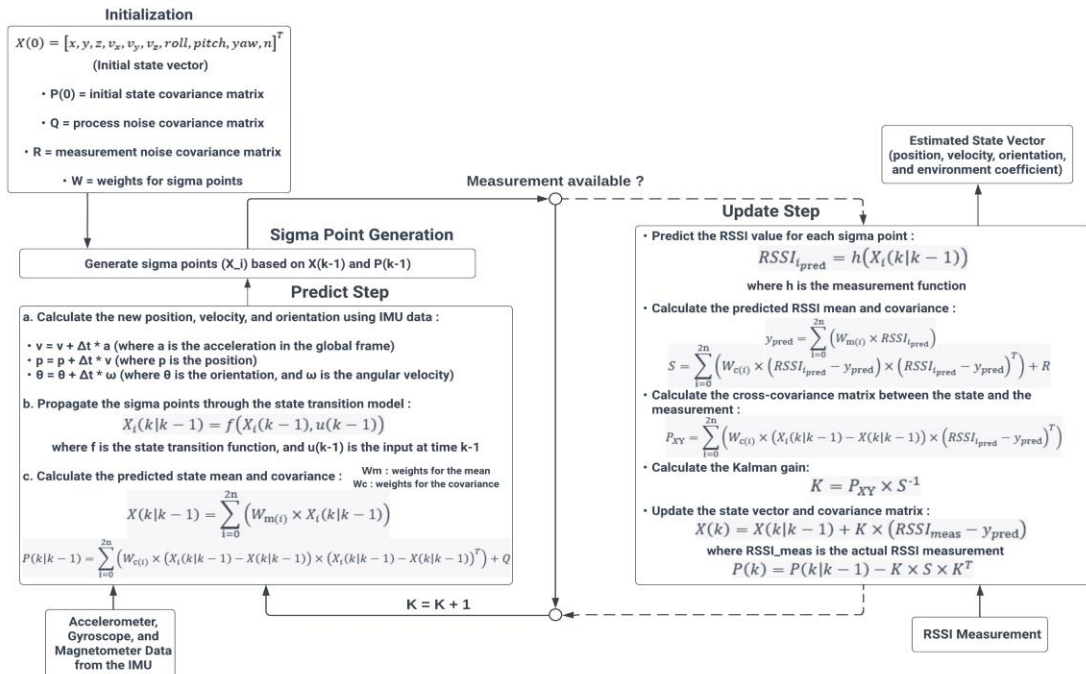


Figure 14: Schéma qui montre l'algorithme du UKF avec les équations.

La liste des variables utilisé :

- $X(0)$: Vecteur d'état initial qui comprend la position (x, y, z) , la vitesse (v_x, v_y, v_z) , l'orientation (roulis, tangage, lacet) et le coefficient d'environnement (n) .
- $P(0)$: Matrice de covariance d'état initiale qui représente l'incertitude du vecteur d'état initial.
- Q : Matrice de covariance de bruit de processus qui modélise l'incertitude dans la fonction de transition d'état.
- R : Matrice de covariance de bruit de mesure qui modélise l'incertitude dans la fonction de mesure.
- W_m : Poids des points sigma utilisés pour calculer la moyenne de l'état prédit et de la mesure prédite.
- W_c : Poids des points sigma utilisés pour calculer la covariance de l'état prédit et de la mesure prédite.
- v : Vecteur de vitesse mis à jour à l'aide des données IMU.
- p : Vecteur de position mis à jour à l'aide du vecteur de vitesse et des données IMU.
- θ : Vecteur d'orientation mis à jour à l'aide de la vitesse angulaire et des données IMU.
- a : Vecteur d'accélération dans le repère global obtenu à partir des données IMU.
- $X_i(k|k-1)$: Points sigma propagés à travers la fonction de transition d'état.
- f : Fonction de transition d'état qui associe l'état actuel et l'entrée à l'état suivant.
- $u(k-1)$: Entrée au temps $k-1$.

- $X(k|k - 1)$: Moyenne de l'état prédit calculée à l'aide de la moyenne pondérée des points sigma.
- $P(k|k - 1)$: Covariance d'état prédite calculée à l'aide de la moyenne prédite de l'état et de la somme pondérée des produits externes des différences entre les points sigma et la moyenne prédite de l'état.
- h : Fonction de mesure qui associe l'état à la mesure prédite.
- $RSSI_{i_{pred}}$: Valeur de RSSI prédite pour chaque point sigma calculée à l'aide de la distance de la balise et du coefficient d'environnement.
- y_{pred} : Moyenne de RSSI prédite calculée à l'aide de la moyenne pondérée des valeurs de RSSI prédites pour chaque point sigma.
- S : Covariance de RSSI prédite calculée à l'aide de la moyenne prédite de RSSI et de la somme pondérée des produits externes des différences entre les valeurs de RSSI prédites et la moyenne prédite de RSSI.
- P_{XY} : Matrice de covariance croisée qui représente la corrélation entre l'état prédit et la mesure prédite.
- K : Gain de Kalman qui détermine la contribution de la mesure à l'état et à la covariance mis à jour.
- $RSSI_{meas}$: Mesure de RSSI réelle qui est utilisée pour mettre à jour le vecteur d'état.
- $X(k)$: Moyenne de l'état mise à jour calculée à l'aide de la moyenne prédite de l'état et du gain de Kalman.
- $P(k)$: Covariance de l'état mise à jour qui est calculée en utilisant la covariance prédite de l'état et le gain de Kalman.

3.4. Différence entre EKF et UKF :

Dans les applications du monde réel, nous rencontrons souvent des équations non linéaires, car la prédiction peut se faire dans une direction tandis que la lecture du capteur se fait dans une autre direction, ce qui implique des angles et des fonctions trigonométriques non linéaires. Ainsi, l'Extended Kalman Filter (EKF) utilise la série de Taylor (et la matrice jacobienne par la suite) pour estimer linéairement une fonction non linéaire autour de la moyenne du gaussien, puis prédit les valeurs. Cependant, l'Unscented Kalman Filter (UKF) s'avère être plus performant [31].

Dans l'Extended Kalman Filter (EKF), nous prenons un seul point, qui correspond à la moyenne de la distribution gaussienne, afin d'estimer une nouvelle fonction linéaire à partir de la fonction non linéaire, comme illustré dans la Figure 15.

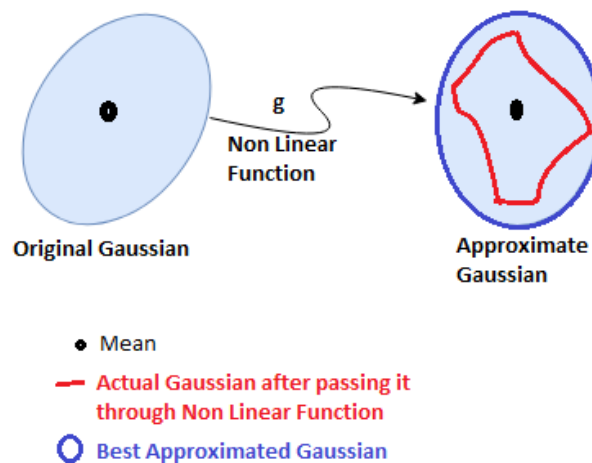


Figure 15: Scénario d'Approximation Gaussienne en EKF Autour de la Moyenne.

Dans EKF, nous utilisons un seul point (la moyenne) pour réaliser une approximation autour de ce point, tandis qu'en UKF, nous utilisons un ensemble de

points comprenant la moyenne et d'autres points, et nous effectuons une approximation autour de ces multiples points. Ainsi, l'utilisation de UKF permettra d'obtenir une meilleure approximation de la fonction non linéaire.

Ici, la principale différence avec EKF réside dans la manière dont les points sont pris en compte pour l'approximation. Dans EKF, seule la moyenne est utilisée comme point d'approximation, tandis que dans UKF, un ensemble de points, appelés points sigma, est utilisé pour l'approximation. Plus précisément, plus le nombre de points sigma est élevé, plus notre approximation sera précise, comme illustré dans la Figure 16.

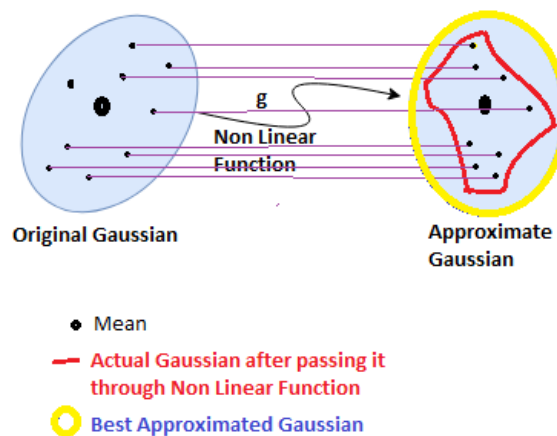


Figure 16: Scénario d'Approximation Gaussienne Autour de la Moyenne et d'Autres Points Sigma.

Dans la Figure 17, vous pouvez voir la comparaison du calcul du gain de Kalman en EKF et en UKF.

$$\begin{array}{l}
 \boxed{
 \begin{array}{l}
 S = H_j P' H_j^T + R \\
 K = P' H_j^T S^{-1}
 \end{array}
 } \Rightarrow EKF
 \end{array}$$

$$\boxed{
 \begin{array}{l}
 T = \sum_{i=0}^{2n} w^{[i]} \underbrace{(X^{[i]} - \mu')(Z^{[i]} - \hat{z})^T}_{\Rightarrow P' H_j^T} \\
 S = \sum_{i=0}^{2n} w^{[i]} (Z^{[i]} - \hat{z})(Z^{[i]} - \hat{z})^T + Q \\
 K = T \cdot S^{-1}
 \end{array}
 } UKF$$

Figure 17: Comparaison du Calcul du Gain de Kalman en EKF et en UKF.

3.5. Calcul d'Erreur :

3.5.1. Erreur de Distance Euclidienne :

Afin de calculer l'erreur de distance euclidienne entre les trajectoires réelle et estimée à chaque instant, il est nécessaire de calculer les différences entre les coordonnées x et y correspondantes des deux trajectoires. Ces différences représentent l'erreur dans les coordonnées x et y entre les trajectoires réelle et estimée à chaque instant. Ensuite, la formule (33) peut être utilisée pour calculer la distance euclidienne entre les trajectoires réelle et estimée à chaque instant. Les valeurs d'erreur résultantes peuvent être représentées graphiquement en fonction du temps pour visualiser l'erreur entre les trajectoires réelle et estimée au fil du temps, permettant ainsi d'évaluer l'exactitude de la trajectoire estimée.

$$distance_ec = \sqrt{(x_{est} - x_{true})^2 + (y_{est} - y_{true})^2} \quad (33)$$

« x_est » et « y_est » sont respectivement les coordonnées x et y estimées à un instant donné, tandis que « x_true » et « y_true » sont les coordonnées x et y réelles correspondantes au même instant.

3.5.2. RMSE :

L'erreur quadratique moyenne d'un estimateur $\hat{\theta}$ d'un paramètre θ de dimension 1 (mean squared error (MSE), en anglais) est une mesure caractérisant la précision de cet estimateur. Elle est plus souvent appelée erreur quadratique (moyenne étant sous-entendu) ; elle est parfois appelée aussi risque quadratique.

L'erreur sera calculée par l'équation (34) et le MSE sera calculée par l'équation (35) comme indiqué ci-dessous [32].

$$err_i = \|Y_i - \hat{Y}_i\| \quad (34)$$

Y_i Est la valeur de position réelle, \hat{Y}_i est la valeur de position estimée et n est le nombre d'observations tel que $Y_i = (x, y, z)$.

$$MSE = \frac{1}{n} \sum_{i=1}^n \|Y_i - \hat{Y}_i\|^2 \quad (35)$$

Une fois que la MSE a été obtenue, on calcule la racine carrée de l'erreur quadratique moyenne pour obtenir le RMSE.

3.5.3. Erreur Relative :

Pour calculer l'erreur relative en pourcentage de la localisation :

1. Calculer l'erreur relative dans la direction x .

$$relative_error_x = \left\| \frac{estimated_x - true_x}{true_x} \right\| \quad (36)$$

Cette équation calcule la différence entre la coordonnée x estimée ($estimated_x$) et la coordonnée x réelle ($true_x$). Elle divise ensuite cette différence par la coordonnée x réelle pour obtenir l'erreur relative. La valeur absolue de la différence est prise pour garantir que l'erreur est toujours positive.

2. Calculer l'erreur relative dans la direction y :

$$relative_error_y = \left\| \frac{estimated_y - true_y}{true_y} \right\| \quad (37)$$

Cette équation calcule la différence entre la coordonnée y estimée ($estimated_y$) et la coordonnée y réelle ($true_y$). Elle divise ensuite cette différence par la coordonnée y réelle pour obtenir l'erreur relative. La valeur absolue de la différence est prise pour garantir que l'erreur est toujours positive

3. Combinez les erreurs relatives dans les directions x et y pour obtenir l'erreur relative totale :

$$total_relative_error = \sqrt{(relative_error_x^2 + relative_error_y^2)} \quad (38)$$

Cette équation utilise le théorème de Pythagore pour combiner les erreurs relatives dans les directions x et y. Le carré de l'erreur relative dans la direction x est ajouté au carré de l'erreur relative dans la direction y, puis la racine carrée est prise pour obtenir l'erreur relative totale.

4. Calculez la moyenne de l'erreur relative totale :

$$relative_error_total = \frac{1}{N} \times total_relative_error \times 100 \quad (39)$$

Où N est le nombre de points dans la trajectoire. Cette équation calcule la moyenne des valeurs d'erreur relative totale obtenues à l'étape 3. La multiplication par 100 convertit l'erreur moyenne d'un nombre décimal en un pourcentage.

CHAPITRE 4

TESTS ET RÉSULTATS

4.1. Simulation:

La scène de l'expérience de simulation est placée sur un terrain de jeu avec une longueur, largeur et hauteur de $350 \times 250 \times 50$ m, comme illustré dans la Figure 18. Le cercle rouge représente l'emplacement de la station de base, tandis que les points verts indiquent les coordonnées d'origine.




Figure 18: Scène d'Expérience de la Simulation.

Nous avons utilisé MATLAB Robotics System Toolbox™ [33], qui permet de générer automatiquement des trajectoires de mouvement en définissant la position et l'attitude des points de cheminement de trajectoire à l'aide de cette boîte à outils. L'état de mouvement cible comprend le mouvement linéaire, le mouvement circulaire,

l'accélération, la décélération, le mouvement uniforme, etc. La trajectoire simulée est affichée dans la Figure 19, avec une vitesse contrôlée à 6 m/s.

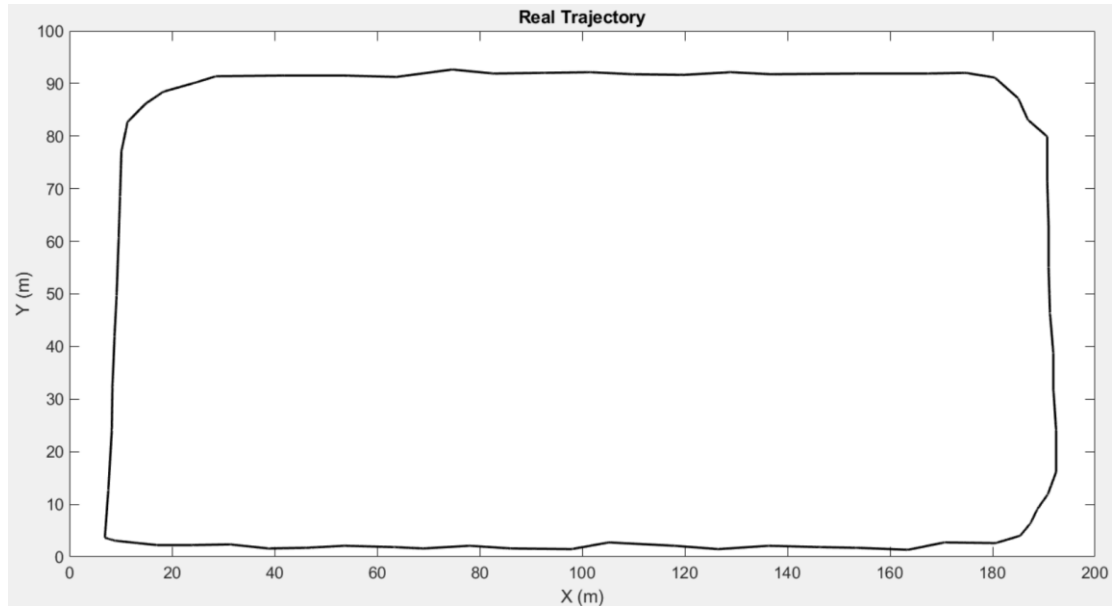


Figure 19: Trajectoire réelle du véhicule lors de la simulation.

Afin de vérifier l'efficacité des algorithmes, nous implémentons l'algorithme de trilatération en utilisant uniquement les valeurs RSSI provenant des balises BLE et nous avons combiné les données IMU avec la valeur RSSI en utilisant EKF et UKF.

4.1.1. Trilatération :

Pour la méthode de trilatération, la trajectoire estimée est indiquée dans la Figure 20 :

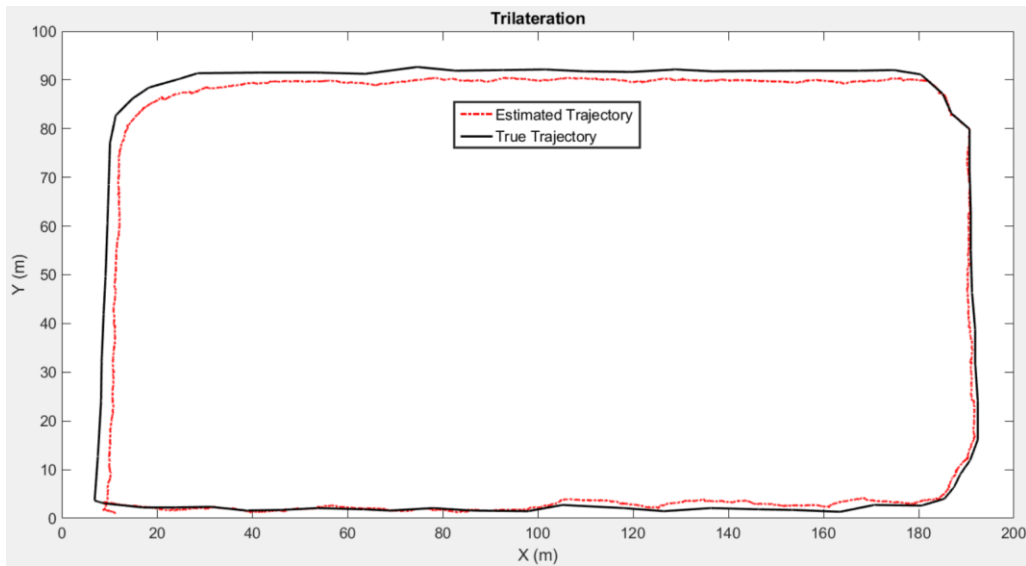


Figure 20: Trajectoire estimée par trilatération comparée à la trajectoire réelle.

Les résultats obtenus en utilisant la méthode de trilatération révèlent une erreur quadratique moyenne (RMSE) de 2.249 mètres. En ce qui concerne les erreurs relatives, nous constatons une erreur relative totale de 12.365 %. Ces valeurs fournissent des informations sur la performance de la méthode de trilatération pour estimer la trajectoire du véhicule par rapport à sa trajectoire réelle au cours de cette simulation.

4.1.2. EKF :

Pour la méthode de EKF, la trajectoire estimée est indiquée dans la Figure 21 :




Figure 21: Trajectoire estimée par EKF comparée à la trajectoire réelle.

Les résultats obtenus en utilisant l'Extended Kalman Filter (EKF) révèlent une erreur quadratique moyenne de 1.391 mètres. L'erreur relative est de 6.803 %. Ces valeurs indiquent la performance de la méthode EKF pour estimer la trajectoire du véhicule par rapport à sa trajectoire réelle, démontrant une amélioration significative par rapport à la méthode de trilatération.

4.1.3. UKF :

Pour la méthode du UKF, la trajectoire estimée est indiquée dans la Figure 22:

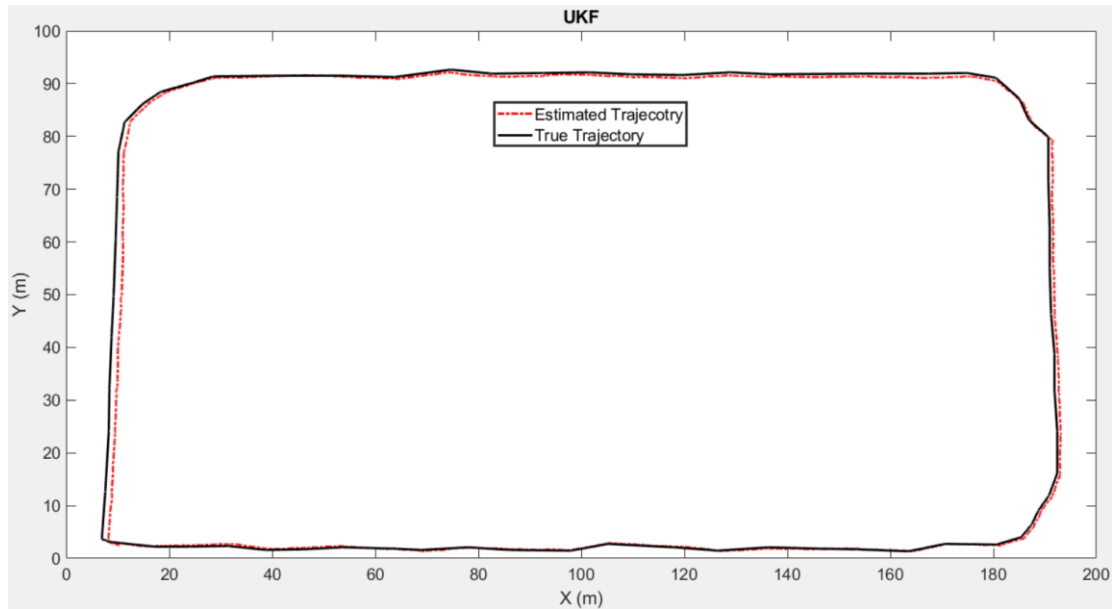


Figure 22: Trajectoire estimée par UKF comparée à la trajectoire réelle.

Les résultats obtenus en utilisant l'Unscented Kalman Filter (UKF) montrent une erreur quadratique moyenne de 0.820 mètres. L'erreur relative est de 5.736 %. Ces valeurs indiquent la performance de la méthode UKF pour estimer la trajectoire du véhicule par rapport à sa trajectoire réelle, démontrant une amélioration significative par rapport aux méthodes de trilatération et d'EKF. L'UKF semble offrir la meilleure précision pour l'estimation de la localisation parmi ces méthodes.

4.2. Environnement universitaire :

4.2.1. Scénarios :

Dans le contexte universitaire, la localisation précise est cruciale pour améliorer l'efficacité et la sécurité du campus. Cependant, l'utilisation du GPS pour la localisation en intérieur est souvent limitée en raison de la faible réception du signal, en particulier dans les couloirs et les zones confinées. Afin d'explorer des alternatives pour pallier cette limitation, des tests et mesures ont été réalisés dans un environnement universitaire, plus précisément dans un couloir de longueur de 50 m et un autre de 30 m montré dans la Figure 23. Pour connaître la trajectoire réelle, j'ai marqué quelques points sur le sol dont je connais déjà leurs coordonnées, et lors du test, j'ai inséré une marque dans les données (Je vais appuyer sur un bouton où il va insérer une marque dans les données collectées au moment spécifique) à chaque fois que je passe sur un de ces point.



Figure 23: Le couloir dans l'université

Deux algorithmes de fusion de capteurs, à savoir l'Extended Kalman Filter (EKF) et l'Unscented Kalman Filter (UKF), ont été évalués dans deux scénarios distincts. Dans le premier scénario, une seule balise BLE a été installée dans le couloir, tandis qu'un téléphone Samsung S21 Ultra, positionné sur une chaise à roulettes, a été utilisé pour se déplacer sur une distance d'environ 45 mètres en suivant une trajectoire presque droite, comme illustré dans la Figure 24.

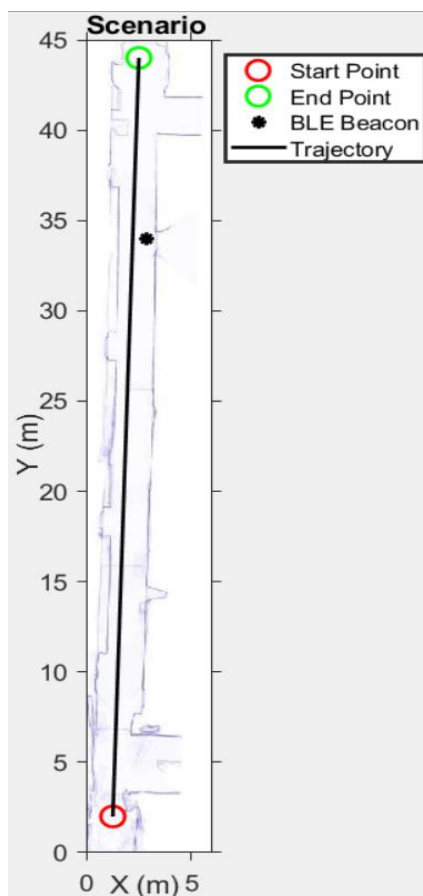


Figure 24: Premier scénario dans l'université.

Dans le deuxième scénario, trois balises BLE ont été installées dans le couloir. Le téléphone a été déplacé initialement sur une distance d'environ 45 mètres en suivant une trajectoire presque droite, puis il a effectué une rotation vers la droite pour parcourir 25 mètres supplémentaires, comme illustré dans la Figure 25.




Figure 25: Deuxième scénario dans l'université.

4.2.2. Résultats :

Les valeurs RSSI et les données de l'IMU (accéléromètre, gyroscope et magnétomètre) ont été mesurées à l'aide de deux applications installées sur le téléphone Samsung S21 Ultra.

Grâce à ces tests et mesures, nous avons pu évaluer et comparer les performances des algorithmes EKF et UKF dans les deux scénarios, ce qui a permis de recueillir des informations précieuses pour le développement de solutions de localisation adaptées aux environnements universitaires. Les résultats de l'estimation du coefficient

d'environnement, présentés dans la Figure 26, se situent dans une fourchette allant de 2.47 à 3.5.

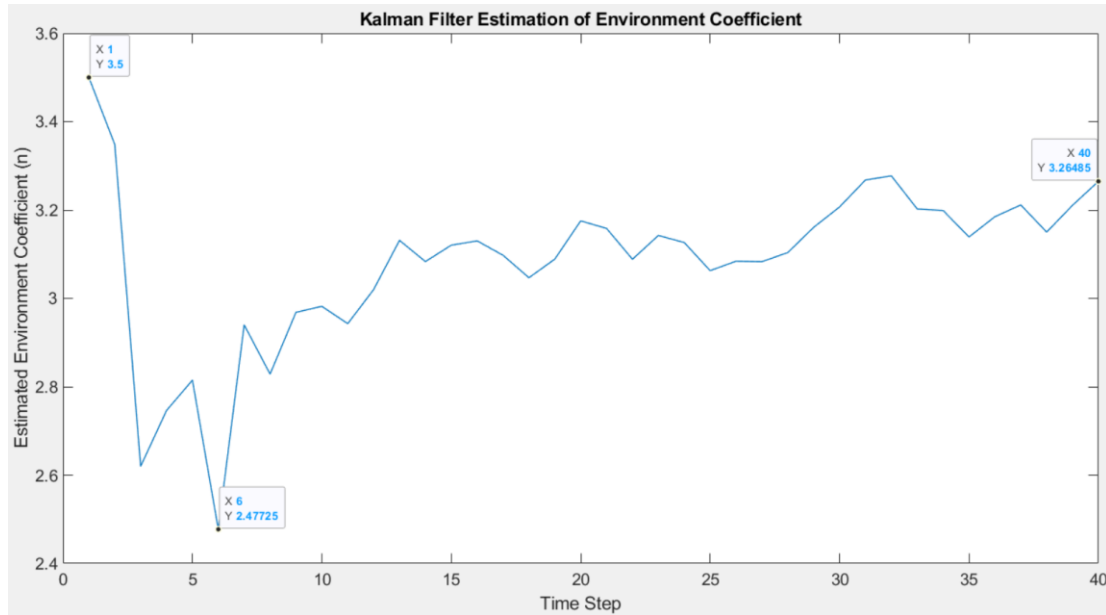


Figure 26: Estimation du coefficient d'environnement dans l'université.

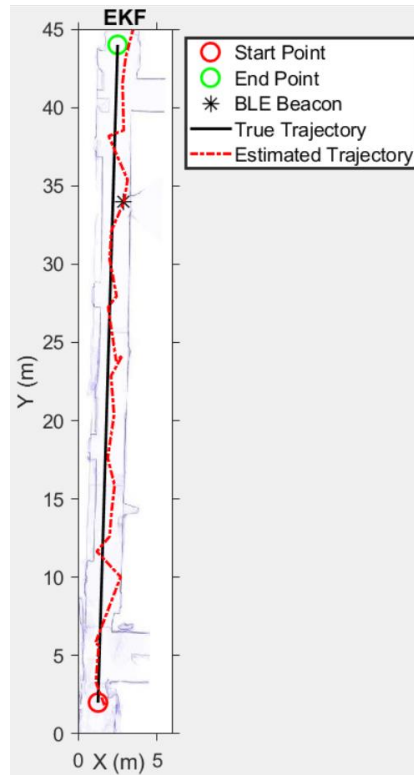


Figure 27: Première Compagne de Mesures.

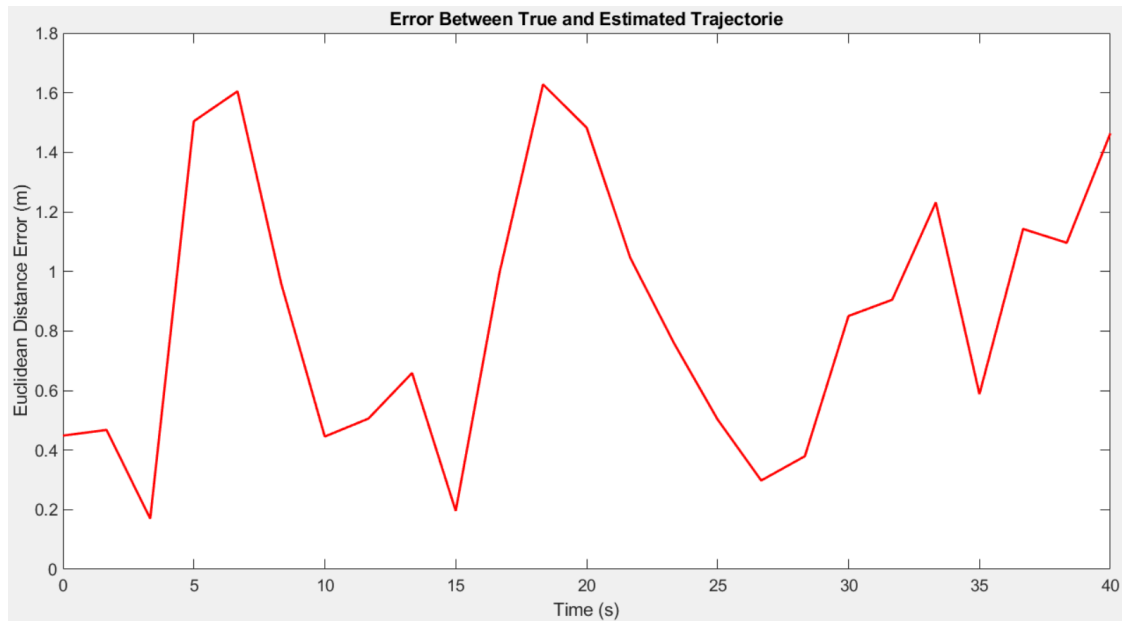


Figure 28: l'Erreur par Rapport au Temps

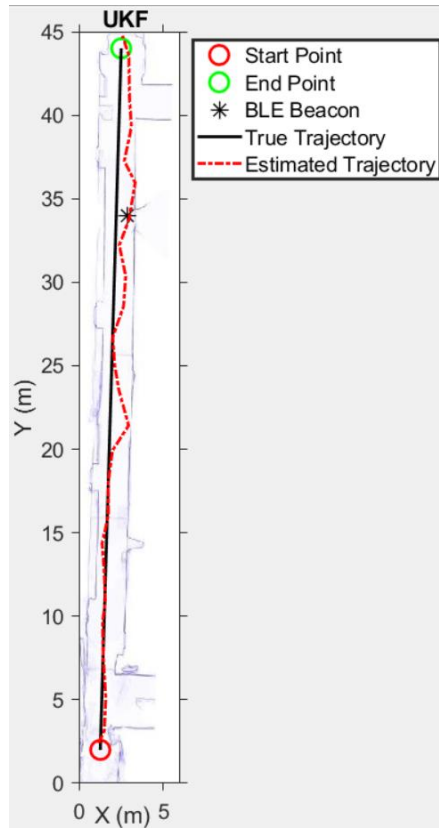


Figure 29: Première Campagne de Mesures.




Figure 30: l'Erreur par Rapport au Temps

Lors du premier scénario, en utilisant l'algorithme EKF pour estimer la position, comme illustré dans la Figure 27, nous avons obtenu une erreur quadratique moyenne (RMSE) de 0.864 m. Cette erreur est représentée la Figure 28 tandis que l'erreur relative a été évaluée à 20.015 %. En utilisant l'algorithme UKF dans le même scénario, comme illustré dans la Figure 29, les résultats ont montré une amélioration avec une RMSE de 0.456 m. Cette erreur est représentée dans la Figure 30, tandis que l'erreur relative a été évaluée à 12.021 %. La comparaison entre les performances des algorithmes EKF et UKF dans le scénario avec une seule balise BLE est présentée dans la Figure 31, où l'on peut observer que l'UKF surpasse l'EKF en termes d'erreur obtenue.

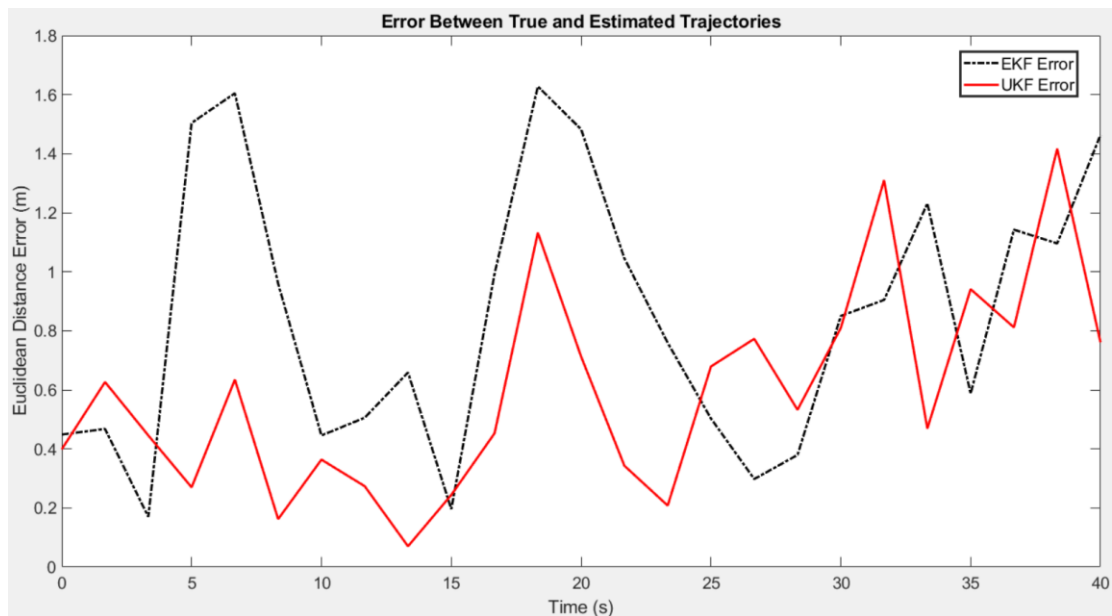


Figure 31: Comparaison Entre les Deux Erreur par Rapport au Temps

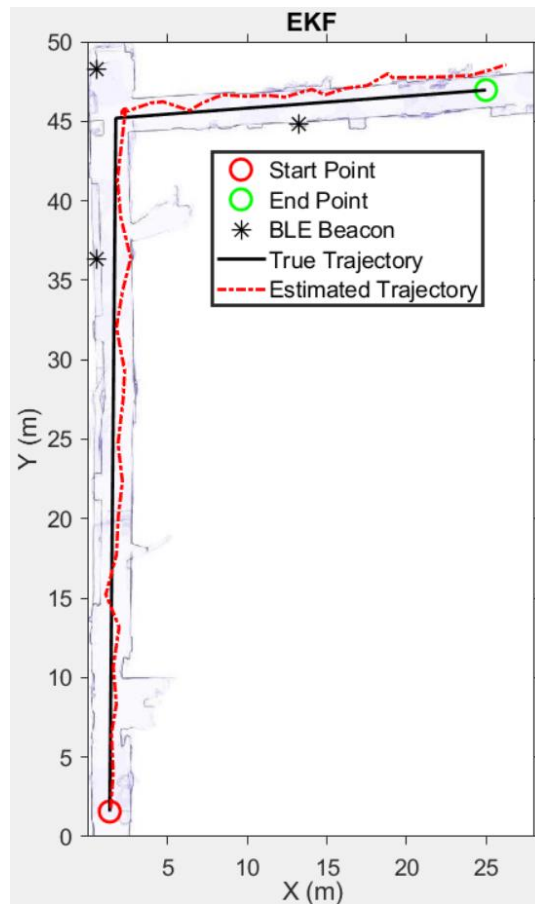


Figure 32: Seconde Campagne de Mesures.

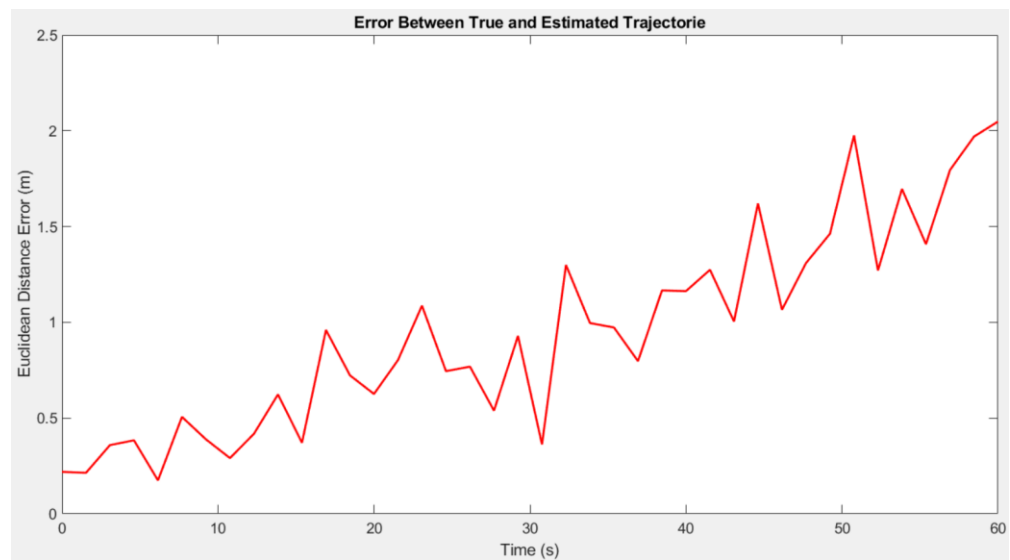


Figure 33: l'Erreur par Rapport au Temps

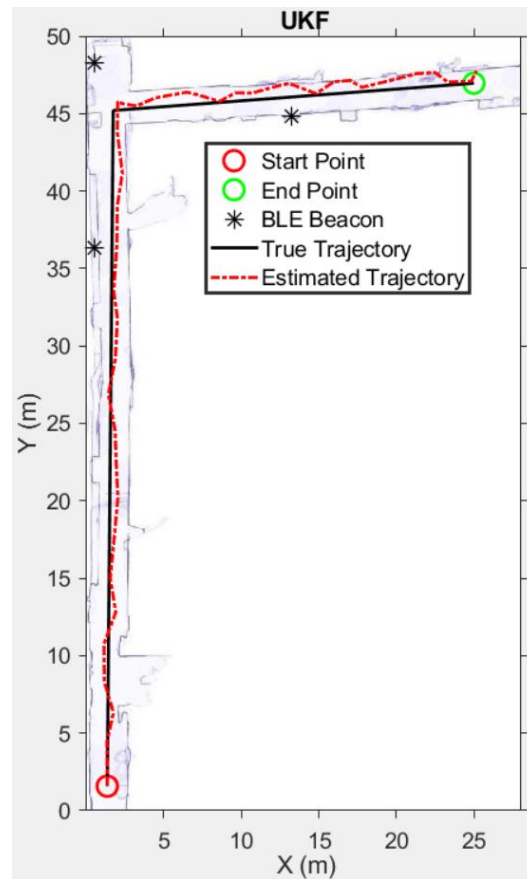


Figure 34: Seconde Compagne de Mesures.




Figure 35: l'Erreur par Rapport au Temps

Dans le deuxième scénario, où trois balises BLE ont été utilisées, le résultat en appliquant EKF montré dans la Figure 32, a produit une RMSE de 0.944 m, cette erreur est affichée dans la Figure 33 tandis que l'erreur relative de 18.512 %.

En revanche, l'UKF a montré une performance encore meilleure, comme le montre la Figure 34, avec une RMSE de 0.502 m. Cette erreur est affichée dans la Figure 35, tandis que l'erreur relative de 10.156 %. L'amélioration significative de la précision en utilisant l'UKF est mise en évidence dans ce scénario également, comme en témoigne la comparaison entre les erreurs obtenues par les deux algorithmes, illustrée dans la Figure 36. La vitesse varie entre 0.1 et 1.5 m/s.

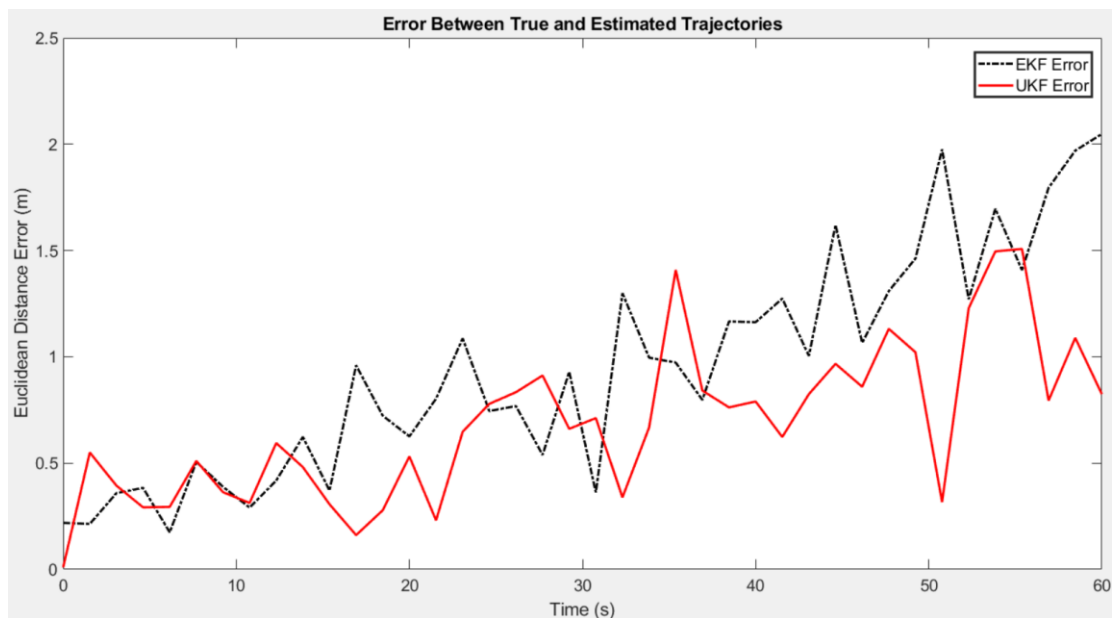


Figure 36: Comparaison Entre les Deux Erreur par Rapport au Temps

Les résultats synthétisés dans le Tableau II illustrent que l'UKF surpasse l'EKF en termes de précision et d'erreur relative dans les deux scénarios testés. Il est important de noter que l'UKF a démontré une performance nettement supérieure, avec des erreurs considérablement réduites par rapport à l'EKF.

Tableau II: Comparaison des performances de l'EKF et du UKF dans les deux scénarios dans l'université.

Scénario	Algorithme	RMSE (m)	Erreur relative (%)
Premier	EKF	0.864	20.015
Premier	UKF	0.456	12.021
Deuxième	EKF	0.944	18.512
Deuxième	UKF	0.502	10.156

4.2.3. Comparaison des résultats avec d'autres travaux existants

Lorsque nous comparons les résultats obtenus dans notre projet avec ceux d'autres systèmes de localisation développés pour des environnements intérieurs, il est évident que notre approche offre de meilleures performances. Par exemple, dans le projet [34] intitulé "IMU-Based Indoor Localization for Construction Applications using Kalman Filter", les auteurs ont obtenu une erreur de position de 3.67 m dans une zone de 250 m. Dans un autre projet [35] intitulé "Indoor Tracking by Adding IMU and UWB Using Unscented Kalman Filter", les auteurs ont obtenu une erreur de localisation comprise entre 2.93 m et 1.65 m en utilisant 4 balises UWB avec des filtres EKF/UKF, et entre 2.65 m et 0.94 m en utilisant jusqu'à 16 balises. Le coefficient d'environnement utilisé dans ce projet est égal à 2.6.

Ces résultats indiquent que le système développé dans notre projet offre de meilleures performances que les autres projets réalisés dans des environnements

intérieurs. De plus, le coefficient d'environnement estimé par notre filtre est similaire à celui utilisé dans les autres projets, ce qui prouve que notre système est capable d'estimer correctement le coefficient d'environnement, adaptant ainsi la localisation à différents contextes.

4.3. *Environnement Industrielle souterraine:*



Figure 37: Photographie de l'environnement minier.



Figure 38: Photographie du véhicule dans la mine lors des mesures.

4.3.1. Scénario :

Dans les environnements industriels souterrains, tels que les mines, la localisation des véhicules est un enjeu crucial pour la sécurité et l'efficacité des opérations. Cependant, le signal GPS est impossible dans ces environnements, ce qui rend nécessaire l'exploration de solutions alternatives pour la localisation des véhicules. Dans cette optique, des mesures et des tests ont été réalisés dans la mine souterraine "Cité De L'Or" située à Val-D'or, à environ 700 km au nord de Montréal, au Québec, Canada, comme illustré dans la Figure 37. L'objectif était de localiser avec précision un véhicule en mouvement, comme représenté dans la Figure 38, dans une trajectoire de mesures de 130 m et un autre de 35 m. Pour connaître la trajectoire réelle, j'ai marqué quelques points sur le sol dont je connais déjà leurs coordonnées, et lors du test, j'ai inséré une marque dans les données (Je vais appuyer sur un bouton où il va insérer une marque dans les données collectées au moment spécifique) à chaque fois que je passe sur un de ces point.




Figure 39: Premier scénario dans la mine.

Deux algorithmes de localisation, l'EKF et le UKF, ont été testés dans deux scénarios différents. Dans les deux cas, 5 balises Bluetooth Low Energy (BLE) ont été installées. Pour le premier scénario, comme illustré dans la Figure 39, les mesures ont été prises en conduisant un véhicule sur une distance d'environ 125 mètres en ligne presque droite.




Figure 40: Deuxième scénario dans la mine.

Dans le deuxième scénario illustré dans la Figure 40, le véhicule a d'abord parcouru 100 mètres en ligne presque droite, puis a effectué un virage à droite et parcouru 20 mètres supplémentaires. La vitesse du véhicule variait entre 0.25 et 3.6 m/s.

Les valeurs de puissance du signal reçu (RSSI) et les données de l'unité de mesure inertielle (IMU) comprenant l'accéléromètre, le gyroscope et le magnétomètre ont été mesurées à l'aide d'un téléphone Samsung S21 Ultra et deux applications différentes. Ces données ont ensuite été utilisées pour estimer la position du véhicule en utilisant les algorithmes EKF et UKF.

4.3.2. Résultats :




Figure 41: Estimation du coefficient d'environnement dans la mine.

Premièrement, le coefficient d'environnement estimé par le filtre Kalman est entre 3.04 et 3.63 comme montre la Figure 41.




Figure 42: Première Compagne de Mesures.




Figure 43: l'Erreur par Rapport au Temps




Figure 44: Première Compagne de Mesures.




Figure 45: l'Erreur par Rapport au Temps

Dans cette étude, l'objectif principal était d'examiner l'efficacité des algorithmes EKF et UKF pour la localisation de véhicules dans un environnement souterrain industriel où le signal GPS est inexistant. Les résultats obtenus montrent que les deux filtres ont réussi à estimer la position du véhicule avec une précision satisfaisante.

Dans le premier scénario, l'utilisation de l'algorithme EKF a conduit à une erreur quadratique moyenne (RMSE) de 1.357 m et une erreur relative de 8.024 %. Les résultats sont présentés dans la Figure 42, et l'évolution de l'erreur par rapport au temps est illustrée dans la Figure 43. En revanche, l'algorithme UKF a permis d'obtenir une RMSE de 0.846 m et une erreur relative de 5.517 %. Ces résultats sont représentés dans la Figure 44 et l'évolution de l'erreur par rapport au temps est illustrée dans la Figure 45. La comparaison entre l'erreur obtenue par les deux algorithmes est illustrée dans la Figure 46.




Figure 46: Comparaison Entre les Deux Erreur par Rapport au Temps




Figure 47: Seconde Compagne de Mesures.




Figure 48: l'Erreur par Rapport au Temps




Figure 49: Seconde Compagne de Mesures.




Figure 50: l'Erreur par Rapport au Temps

Dans le deuxième scénario, en utilisant l'EKF, une RMSE de 1,439 m et une erreur relative de 8,452 % ont été obtenues, comme le montre la Figure 47. L'erreur par rapport au temps est présentée graphiquement dans la Figure 48. En revanche, en employant l'UKF, une RMSE de 1,035 m et une erreur relative de 6,403 % ont été obtenues, comme indiqué dans la Figure 49, l'erreur par rapport au temps est affichée dans la Figure 50. Il est intéressant de noter que l'UKF a démontré une meilleure performance dans les deux scénarios par rapport à l'EKF, mettant ainsi en évidence l'avantage de l'UKF. La comparaison entre l'erreur obtenue par les deux algorithmes est illustrée dans la Figure 51.




Figure 51: Comparaison Entre les Deux Erreur par Rapport au Temps

4.3.3. Pour mieux comprendre les résultats :

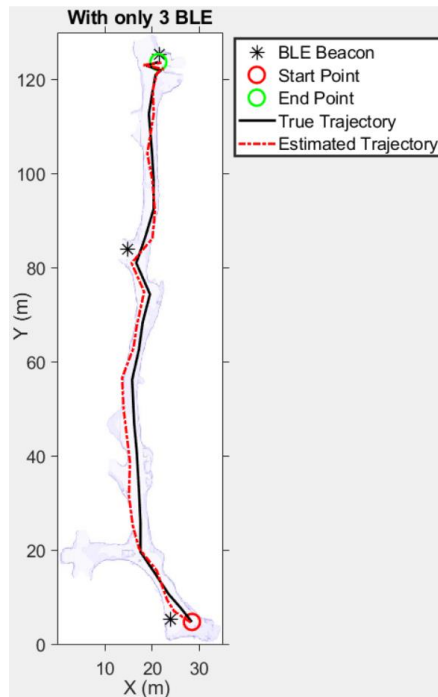


Figure 52: Trajectoire estimée comparée à la trajectoire réelle en annulant 2 balises dans la mine.

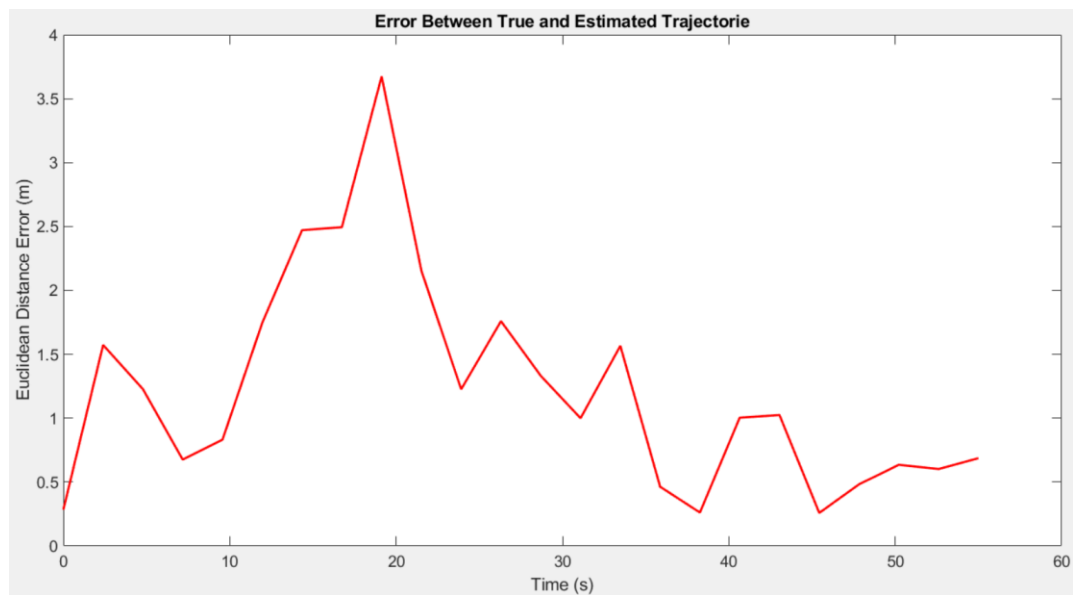


Figure 53: l'Erreur par Rapport au Temps

Pour démontrer plus amplement l'efficacité du système, deux balises BLE ont été retirées, laissant seulement trois balises utilisées, montre la Figure 52, avec 80 m entre la première et la deuxième balise (en partant du bas) et 45 m entre la deuxième et la troisième. Les résultats montrent une RMSE de 1.045 m et une erreur relative de 6.295 % pour la trajectoire totale.

Lorsque l'on effectue le calcul de la RMSE et de l'erreur relative exclusivement entre les deux premières balises, les résultats s'élèvent respectivement à 1,445 m et 9,257 %. Entre la deuxième et la troisième balise, ces valeurs sont de 0,6122 m et 3,644 %. L'erreur relative au temps est présentée graphiquement la Figure 53. Ces résultats soulignent la capacité du système à s'adapter à des conditions de fonctionnement moins optimales, notamment lorsque seul un nombre restreint de balises BLE est utilisé.

Ces observations démontrent que le système utilisé est capable d'estimer la position du véhicule même en présence de balises BLE défaillantes. La RMSE plus élevée entre les deux premières balises par rapport à celle entre la deuxième et la troisième est tout à fait attendue, car une fois que le téléphone perd la connexion avec la première balise, la localisation se fonde uniquement sur les données de l'IMU, ce qui peut induire une dérive temporelle. Néanmoins, dès que le téléphone capte le signal de la deuxième balise, la trajectoire estimée s'améliore.




Figure 54: Trajectoire estimée comparée à la trajectoire réelle en annulant tous les balises dans la mine.

Enfin, afin d'illustrer l'impact significatif de l'utilisation des balises BLE sur l'amélioration du système de localisation, toutes les balises BLE ont été retirées, comme le montre la Figure 54. Les résultats ont conduit à une RMSE de 5,715 m et une erreur relative de 25,074 %, indiquant une estimation de localisation très peu satisfaisante. Cette comparaison souligne l'importance cruciale des balises BLE dans le processus de localisation. Ces résultats synthétisés dans le Tableau III, mettent en évidence que l'UKF surpasse l'EKF en termes de précision et d'erreur relative dans les deux scénarios évalués. Il est important de noter que l'UKF a manifesté une performance nettement supérieure, se traduisant par des erreurs considérablement réduites par rapport à l'EKF.

Tableau III: Comparaison des performances de l'EKF et du UKF dans les deux scénarios dans la mine.

Scénario	Algorithme	RMSE (m)	Erreur relative (%)
Premier	EKF	1.357	8.024
Premier	UKF	0.846	5.517
Deuxième	EKF	1.439	8.452
Deuxième	UKF	1.035	6.403

4.3.4. Comparaison des résultats avec d'autres travaux existants :

En comparant les résultats obtenus dans cette étude avec d'autres systèmes de localisation développés précédemment pour les mines souterraines, nous pouvons constater une amélioration significative des performances. Par exemple, dans le projet [36] intitulé "Underground Coal Mine Positioning System Based on RSSI Positioning Algorithm Improved Through the BP Learning Training", un taux d'erreur de positionnement compris entre 15 et 18 % a été observé, et le coefficient d'environnement utilisé était de 3.75. Dans un autre projet [37] intitulé "Underground Miners Localization System Based on ZigBee", une erreur de 2 mètres a été enregistrée dans une zone de 20 mètres, avec un coefficient d'environnement égal à 3.5.

Ces comparaisons mettent en évidence que le système développé dans cette étude présente des performances supérieures à celles des projets antérieurs réalisés dans des mines souterraines. De plus, le coefficient d'environnement estimé par le filtre semble être en adéquation avec les valeurs utilisées dans ces autres projets, ce qui renforce la crédibilité de l'estimation du coefficient d'environnement par le filtre.

CONCLUSION

Après avoir mené ce projet, nous pouvons conclure que les algorithmes de localisation basés sur les filtres EKF et UKF sont efficaces pour estimer la position d'un véhicule dans des environnements dépourvus de signal GPS, tels que les campus universitaires en intérieur et les mines souterraines. Les différentes expérimentations réalisées dans divers scénarios ont démontré que l'utilisation de balises BLE, associées aux données de l'unité de mesure inertielle (IMU), permet d'obtenir des résultats de localisation précis et fiables pour le véhicule. Dans le contexte de l'université en intérieur, l'erreur quadratique moyenne (RMSE) obtenue était d'environ 0.5 m, tandis que dans l'environnement minier, elle était d'environ 1.4 m

En outre, il convient de souligner que le système de localisation développé a démontré sa capacité à continuer à fournir une estimation de position précise même en cas de défaillance de certaines balises BLE. Cela montre que l'approche adoptée est robuste et tolérante aux pannes, permettant une localisation fiable dans des conditions où la disponibilité des balises peut être incertaine ou variable. Cette résilience aux perturbations environnementales est essentielle pour garantir l'efficacité et la fiabilité du système dans des applications réelles et critiques.

Cela atteste de la robustesse de l'approche adoptée, ainsi que de sa tolérance aux pannes, ce qui permet une localisation fiable dans des conditions où la disponibilité des balises peut être incertaine ou variable. Cette résilience aux perturbations environnementales est essentielle pour garantir l'efficacité et la fiabilité du système dans des applications réelles et critiques.

L'un des principaux avantages de l'approche proposée réside dans l'estimation automatique du coefficient d'environnement grâce aux filtres EKF et UKF, conférant ainsi au système une autonomie totale et une capacité d'adaptation à différentes

configurations environnementales, sans nécessiter d'intervention manuelle. Cette caractéristique confère au système une plus grande robustesse et fiabilité, fournissant ainsi une solution viable pour améliorer la sécurité et l'efficacité des opérations dans divers types d'installations.

Les expérimentations ont été réalisées dans des environnements contrôlés tels que les universités intérieures et les mines souterraines simulées, ce qui pourrait ne pas refléter pleinement la complexité des environnements réels. En effet, les conditions réelles peuvent être bien plus variables, incluant des interférences radio supplémentaires, des changements topographiques, et des obstacles imprévus, susceptibles d'affecter la précision du système de localisation.

Un autre aspect essentiel à prendre en considération concerne la gestion des erreurs et des incertitudes liées aux mesures des capteurs. Bien que les filtres EKF et UKF soient conçus pour traiter les non-linéarités et les erreurs, des défis demeurent, notamment la synchronisation des données de capteurs, la gestion des erreurs de modèle, et la dérive des capteurs sur le long terme. Ces aspects doivent être pris en compte afin de garantir des estimations de localisation fiables et précises.

Dans le cadre des perspectives de travaux futurs, diverses améliorations pourraient être envisagées pour le système de localisation, en vue d'obtenir des estimations encore plus précises. L'intégration de capteurs supplémentaires, tels que des lidars ou des caméras, pourrait permettre de fusionner les informations provenant de différentes sources, contribuant ainsi à améliorer la qualité de la localisation. Ces capteurs complémentaires pourraient fournir des données supplémentaires sur les caractéristiques topographiques et les obstacles environnants, ce qui renforcerait la précision des estimations de position et d'orientation.

L'utilisation de capteurs IMU de meilleure qualité permettrait d'améliorer la précision des estimations de position et d'orientation. Des recherches approfondies sur

les spécifications techniques et les caractéristiques des capteurs IMU disponibles sur le marché pourraient orienter la sélection de capteurs offrant les meilleures performances pour des applications spécifiques.

En parallèle, l'adoption de balises BLE 5.1 offrirait de nouvelles fonctionnalités, telles que l'angle d'arrivée (AoA), offrant une meilleure performance et une plus grande précision dans la localisation. L'utilisation de cette technologie pourrait significativement améliorer la précision de la localisation en permettant une détermination plus précise de la direction d'où proviennent les signaux émis par les balises. Cela contribuerait ainsi à une meilleure triangulation et à des estimations plus précises des positions des véhicules.

En explorant ces différentes améliorations, il serait possible de développer un système de localisation encore plus robuste et précis, capable de répondre aux exigences de diverses applications industrielles et souterraines, où la fiabilité et l'exactitude sont essentielles pour assurer la sécurité et l'efficacité des opérations. En menant des recherches approfondies sur ces aspects spécifiques, nous pourrions ouvrir la voie à des avancées significatives dans le domaine de la localisation des véhicules autonomes dans des environnements complexes et exigeants.

RÉFÉRENCES

- [1] Facts and Figures of the Canadian Mining Industry (*Mining Association of Canada*)
- [2] Ge, Shirong, Fei-Yue Wang, Jianjian Yang, Zhen Ding, Xiao Wang, Yuchen Li, Siyu Teng, Zhongmin Liu, Yunfeng Ai, and Long Chen. "Making standards for smart mining operations: Intelligent vehicles for autonomous mining transportation." *IEEE Transactions on Intelligent Vehicles* 7, no. 3 (2022): 413-416.
- [3] Ren, Zhu-Li, Li-Guan Wang, and Lin Bi. "Improved extended Kalman filter based on fuzzy adaptation for SLAM in underground tunnels." *International Journal of Precision Engineering and Manufacturing* 20 (2019): 2119-2127.
- [4] Mouhammad, Camellia S., Ahmed Allam, Mohamed Abdel-Raouf, Ehab Shenouda, and Maha Elsabrouty. "BLE indoor localization based on improved RSSI and trilateration." In *2019 7th International Japan-Africa Conference on Electronics, Communications, and Computations, (JAC-ECC)*, pp. 17-21. IEEE, 2019.
- [5] Deilamsalehy, Hanieh, and Timothy C. Havens. "Sensor fused three-dimensional localization using IMU, camera and LiDAR." In *2016 IEEE SENSORS*, pp. 1-3. IEEE, 2016.
- [6] Malyavej, Veerachai, Warapon Kumkeaw, and Manop Aorpimai. "Indoor robot localization by RSSI/IMU sensor fusion." In *2013 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, pp. 1-6. IEEE, 2013.
- [7] Elmenreich, Wilfried. "Sensor fusion in time-triggered systems." PhD diss., 2002.
- [8] Abdollahzadeh, Milad, Tooba Malekzadeh, and Hadi Seyedarabi. "Multi-focus image fusion for visual sensor networks." In *2016 24th Iranian Conference on Electrical Engineering (ICEE)*, pp. 1673-1677. IEEE, 2016.
- [9] King, A. D. "Inertial navigation-forty years of evolution." *GEC review* 13, no. 3 (1998): 140-149.
- [10] Titterton, David, John L. Weston, and John Weston. *Strapdown inertial navigation technology*. Vol. 17. IET, 2004.
- [11] Woodman, Oliver J. *An introduction to inertial navigation*. No. UCAM-CL-TR-696. University of Cambridge, Computer Laboratory, 2007.

- [12] Farrell, Jay, and Matthew Barth. *The global positioning system and inertial navigation*. Vol. 61. New York: McGraw-hill, 1999.
- [13] Julier, Simon J., and Jeffrey K. Uhlmann. "Unscented filtering and nonlinear estimation." *Proceedings of the IEEE* 92, no. 3 (2004): 401-422.
- [14] Simon, Dan. *Optimal state estimation: Kalman, H infinity, and nonlinear approaches*. John Wiley & Sons, 2006.
- [15] Bluetooth, S. I. G. "Bluetooth Core Specification v5. 0, December 2016."
- [16] Faragher, Ramsey, and Robert Harle. "An analysis of the accuracy of bluetooth low energy for indoor positioning applications." In *Proceedings of the 27th International Technical Meeting of The Satellite Division of the Institute of Navigation (ION GNSS+ 2014)*, pp. 201-210. 2014.
- [17] Yoon, Min Sang, and Ahmed E. Kamal. "Power minimization in fat-tree SDN datacenter operation." In *2015 IEEE Global Communications Conference (GLOBECOM)*, pp. 1-7. IEEE, 2015.
- [18] Mathworks, I. "MATLAB: The Language of Technical Computing: Computation, Visualization, Programming. (R2021a). Version 9.10. 0." (2021).
- [19] Welch, Greg, and Gary Bishop. "An introduction to the Kalman filter." (1995): 2.
- [20] Zafari, Faheem, and Ioannis Papapanagiotou. "Enhancing ibeacon based micro-location with particle filtering." In *2015 IEEE Global Communications Conference (GLOBECOM)*, pp. 1-7. IEEE, 2015.
- [21] iFixit. "Samsung Galaxy S21 Ultra Teardown." Accessed May 3, 2023. <https://www.ifixit.com/Teardown/Samsung+Galaxy+S21+Ultra+Teardown/141188>.
- [22] Mascaro, Ruben, Lucas Teixeira, Timo Hinzmann, Roland Siegwart, and Margarita Chli. "Gomsf: Graph-optimization based multi-sensor fusion for robust uav pose estimation." In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 1421-1428. IEEE, 2018.
- [23] Grewal, Mohinder S., and Angus P. Andrews. *Kalman filtering: Theory and Practice with MATLAB*. John Wiley & Sons, 2014.
- [24] Wan, Eric A., and Rudolph Van Der Merwe. "The unscented Kalman filter for nonlinear estimation." In *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No. 00EX373)*, pp. 153-158. Ieee, 2000.

- [25] Andò, Bruno, Salvatore Baglio, Ruben Crispino, and Vincenzo Marletta. "An introduction to indoor localization techniques. case of study: A multi-trilateration-based localization system with user–environment interaction feature." *Applied Sciences* 11, no. 16 (2021): 7392.
- [26] Sivasakthiselvan, S., and V. Nagarajan. "Localization techniques of wireless sensor networks: A review." In *2020 International Conference on Communication and Signal Processing (ICCSP)*, pp. 1643-1648. IEEE, 2020.
- [27] Fariz, Nik, Norziana Jamil, and Marina Md Din. "An improved indoor location technique using Kalman filtering on RSSI." *Advanced Science Letters* 24, no. 3 (2018): 1591-1598.
- [28] Zhu, Xiao Xiang, Devis Tuia, Lichao Mou, Gui-Song Xia, Liangpei Zhang, Feng Xu, and Friedrich Fraundorfer. "Deep learning in remote sensing: A comprehensive review and list of resources." *IEEE geoscience and remote sensing magazine* 5, no. 4 (2017): 8-36.
- [29] Wan, Eric A., and Rudolph Van Der Merwe. "The unscented Kalman filter for nonlinear estimation." In *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No. 00EX373)*, pp. 153-158. Ieee, 2000.
- [30] Bar-Shalom, Yaakov, X. Rong Li, and Thiagalingam Kirubarajan. *Estimation with applications to tracking and navigation: theory algorithms and software*. John Wiley & Sons, 2001.
- [31] Allotta, Benedetto, Luigi Chisci, Riccardo Costanzi, Francesco Fanelli, Claudio Fantacci, Enrico Meli, Alessandro Ridolfi, Andrea Caiti, Francesco Di Corato, and Davide Fenucci. "A comparison between EKF-based and UKF-based navigation algorithms for AUVs localization." In *OCEANS 2015-Genova*, pp. 1-5. IEEE, 2015.
- [32] Hodson, Timothy O., Thomas M. Over, and Sydney S. Foks. "Mean squared error, deconstructed." *Journal of Advances in Modeling Earth Systems* 13, no. 12 (2021): e2021MS002681.
- [33] Corke, Peter. "Robot manipulator capability in MATLAB: A tutorial on using the robotics system toolbox [tutorial]." *IEEE Robotics & Automation Magazine* 24, no. 3 (2017): 165-166.
- [34] Ibrahima, Magdy, and Osama Moselhib. "IMU-based indoor localization for construction applications." In *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction*, vol. 32, p. 1. IAARC Publications, 2015.

- [35] Krishnaveni, B. Venkata, K. Suresh Reddy, and P. Ramana Reddy. "Indoor tracking by adding IMU and UWB using Unscented Kalman filter." *Wireless Personal Communications* (2022): 1-22.
- [36] Chen, Yan-Xiu. "Underground Coal Mine Positioning System Based on RSSI Positioning Algorithm Improved Through the BP Learning Training." *The Open Fuels & Energy Science Journal* 8, no. 1 (2015).
- [37] Huang, Xuhui, Wei Zhu, and Dongxin Lu. "Underground miners localization system based on ZigBee and WebGIS." In *2010 18th International Conference on Geoinformatics*, pp. 1-5. IEEE, 2010.